

**DETECCIÓN DE EPILEPSIA EN SEÑALES DE ELECTROENCEFALOGRAFÍA,  
MEDIANTE EL USO DE REDES NEURONALES ARTIFICIALES Y MÁQUINAS  
CON VECTORES DE SOPORTE**

**ANDREA CEBALLOS HERRERA**

**UNIVERSIDAD AUTÓNOMA DE OCCIDENTE  
FACULTAD DE INGENIERÍA  
DEPARTAMENTO DE AUTOMÁTICA ELECTRÓNICA  
PROGRAMA DE INGENIERÍA BIOMÉDICA  
SANTIAGO DE CALI  
2010**

DETECCIÓN DE EPILEPSIA EN SEÑALES DE ELECTROENCEFALOGRAFÍA,  
MEDIANTE EL USO DE REDES NEURONALES ARTIFICIALES Y MÁQUINAS  
CON VECTORES DE SOPORTE

ANDREA CEBALLOS HERRERA

Trabajo de Grado para optar por el título de  
Ingeniero Biomédico

Director  
JESÚS ALFONSO LÓPEZ SOTELO  
Ingeniero Electricista, Magíster en Automática y Doctor en Ingeniería.

UNIVERSIDAD AUTÓNOMA DE OCCIDENTE  
FACULTAD DE INGENIERÍA  
PROGRAMA DE INGENIERÍA BIOMÉDICA  
SANTIAGO DE CALI  
2010

Nota de aceptación:

Aprobado por el comité de Grado  
en cumplimiento de los requisitos  
exigidos por la Universidad  
Autónoma de Occidente para optar  
al título de Ingeniero Biomédico

JUAN DIEGO PULGARÍN

Jurado

JUAN CARLOS MENA

Jurado

Santiago de Cali, 12 de Agosto de 2010

A mi mamá...quien aún no conociendo el amor, lo inventó para mí, a quien la vida le arrebató parte de su "chispa" para encender la mía. A todos mis hermanos y hermanas... quienes en sus cortas vidas han transformado la mía, para que yo haga con ella grandes cosas por la vida de los demás. A mi papá... quien le ha puesto obstáculos a muchos de sus sueños para que yo pueda hacer realidad cada uno de los míos. A Graciela... quien fue el punto de partida, la mentor, la prócer y origen de lo que yo conozco como familia.

A mi familia... quienes perdieron toda su paz y salud, para que la humanidad ganara un poco de las dos.

A todas las personas que me han llegado a conocer y aún así permanecen a mi lado

Quiero expresar mis agradecimientos muy sinceros al Dr. Guillermo Barrios quien depositó su confianza en mí, fue mi tutor y el canal para realizar la primera etapa de este trabajo. Por supuesto a la Fundación Liga Colombiana Contra la Epilepsia, Capítulo Valle del Cauca Helena Nader de Zaccour por permitirme el espacio y el tiempo para realizar gran parte de la fundamentación de este proyecto, al señor Álvaro José González quien fue director de la liga durante mi estadía y dio el aval al proyecto, a todos los que trabajaban en la liga pero especialmente a las técnicas María Helena Garcés y Mercedes González quienes son tan sabias en electroencefalografía como en la vida, a todos y cada uno de los pacientes que me dieron su consentimiento para que yo con su “desgracia”-como ellos mismos la llaman- pueda algún día hacer algo por otras personas en las mismas condiciones que ellos.

También quiero darle las gracias a todos los que esperaron mucho y poco de mí. A los compañeros de todo el tiempo de formación y los amigos de toda la vida, por su constancia, por su desinterés, por su autenticidad. A “pulgarcito” compañero de claustro por su acompañamiento y guía desinteresada. Al director de este trabajo quien a ojos cerrados confió en el proyecto y en algunos momentos en su realizadora. Al representante legal de AMBAR CORP. Oswaldo Angulo Vásquez, quien permitió que una de las cosas que yo vine a hacer en este mundo, la empezara hoy y no dentro de 30 años, cuando seguramente sea demasiado tarde.

Y los más especiales agradecimientos son para mi familia: los de sangre y aquellos que no lo son, pero que han convivido conmigo como si lo fueran, por el apoyo moral y físico, por los años de sacrificios personales y colectivos, para que yo hoy este en esta etapa de mi vida. A todos gracias porque siempre por encima de todo confiaron en mí, esperan siempre mucho de mí y no pienso defraudarlos. También quiero agradecer a mi compañero en la vida Andrés Hoyos Idrobo quien me ha ayudado por mucho tiempo ha sacar lo mejor y lo peor de mí, como ingeniera y como persona; me ha ayudado a conocer, para bien y para mal de todo lo que soy capaz.

Finalmente a Dios, que me acompañó en otra etapa académica de mi vida que culmina con este proyecto; cuando lo deje, cuando se lo pedí. De todas formas, se que siempre estuvo ahí, y aunque tengo un conflicto interno en si agradecer o no, lo hago de todas maneras, ha regañadientes, pero con la convicción de que él en su infinita sabiduría sabe el por qué y para qué cambio mi vida en un instante.

## CONTENIDO

	pág.
INTRODUCCIÓN	17
1. MARCO DE REFERENCIA	20
1.1 MARCO DE ANTECEDENTES	19
1.2 MARCO CONCEPTUAL	23
1.2.1 Epilepsia	23
1.2.2 Electroencefalografía	24
1.2.2.1 Montajes	25
1.2.2.2 Tipos de trazado	26
1.2.2.3 Tipos de onda	27
1.3 MARCO TEÓRICO	30
1.3.1 Sistema generalizado de reconocimiento de patrones	31
1.3.2 Pre-procesamiento	30
1.3.2.1 Filtros digitales	31
1.3.2.2 Periodograma	31
1.3.2.3 Análisis espectral auto-regresivo	31
1.3.2.4 Transformada de Fourier	31
1.3.2.5 Transformada discreta wavelet, DWT	31
1.3.3 Procesamiento de señales	32
1.3.3.1 Extracción de Características	32
1.3.3.2 Selección de Características	35

1.3.4	Clasificación y reconocimiento de patrones	35
1.3.4.1	Red Neuronal Artificial Perceptrón Multicapa, MLP	37
1.3.4.2	Red Neuronal Artificial de Base Radial, RBF	39
1.3.4.3	Máquinas con Vectores de Soporte, SVM	40
1.3.5	Evaluación de Desempeño	43
1.3.5.1	Errores de clasificación	43
1.3.5.2	Características operativas del receptor	43
1.3.5.3	Exactitud	43
1.3.5.4	Validación cruzada	43
1.3.5.5	Matriz de confusión	44
1.3.5.6	Indicadores	44
1.4	MARCO LEGAL	45
2.	METODOLOGÍA	46
2.1	TIPO DE ESTUDIO	46
2.2	POBLACIÓN	46
2.3	MUESTRA	46
2.4	RECOLECCIÓN DE LA INFORMACIÓN	47
2.5	MATERIALES Y MÉTODOS	47
2.5.1	Materiales de estudio observacional descriptivo	47
2.5.2	Materiales de estudio observacional evaluativo	48
2.5.3	Métodos de estudio observacional descriptivo	48
2.5.3.1	Recolección de Información	48

2.5.4 Método de estudio observacional evaluativo	50
2.5.4.1 Construcción de Base de Datos	50
2.5.4.2 Pre-procesamiento	51
2.5.4.3 Extracción de Características	53
2.5.4.4 Selección de Características	53
2.5.4.5 Red Perceptrón Multicapa	54
2.5.4.6 Red de Base Radial	55
2.5.4.7 Máquinas con Vectores de Soporte	56
2.5.4.8 Evaluación de Desempeño	56
3. RESULTADOS	57
3.1 ESTUDIO OBSERVACIONAL DESCRIPTIVO	57
3.2 ESTUDIO OBSERVACIONAL EVALUATIVO	58
3.2.1 Construcción de Base de Datos	58
3.2.2 Pre-Procesamiento	59
3.2.3 Procesamiento	59
3.2.3.1 Extracción de Características	59
3.2.3.2 Selección de Características	60
3.2.4 Clasificación	63
3.2.4.1 MLP	63
3.2.4.2 RBF	65
3.2.4.3 SVM	67
3.2.5 Evaluación de Desempeño	70



3.2.5.1	Curvas de error para MLP	70
3.2.5.2	Curvas de error para RBF	72
3.2.5.3	Curvas de error para SVM	73
3.2.5.4	Matrices de confusión para MLP	75
3.2.5.5	Matrices de confusión para RBF	77
3.2.5.6	Matrices de confusión para SVM	78
4.	CONCLUSIONES.	82
	BIBLIOGRAFÍA	84
	ANEXOS	88
	APÉNDICE	

## LISTA DE CUADROS

	pág.
Cuadro 1. Clasificación de montajes para registro de señales de EEG	25
Cuadro 2. Montajes más comunes	26
Cuadro 3. Tipos de Ondas de Vigilia	27
Cuadro 4. Tipos de Ondas de Sueño	28
Cuadro 5. Tipos de Ondas Epileptiformes	29
Cuadro 6. Principios de una SVM	41

## LISTA DE TABLAS

	pág.
Tabla 1. Canales que utiliza la literatura para la tarea de clasificación	54
Tabla 2. Registros obtenidos	57
Tabla 3. Clases de Registros	57
Tabla 4. Registros de la base de datos	58
Tabla 5. Codificación de las características	61
Tabla 6. PCA por canales	61
Tabla 7. PCA por características	62
Tabla 8. Detalles clasificador MLP para mc	63
Tabla 9. Detalles clasificador MLP para mbc	64
Tabla 10. Detalles clasificador RBF para mc	65
Tabla 11. Detalles clasificador RBF para mbc	66
Tabla 12. Detalles clasificador SVM para mc	67
Tabla 13. Detalles clasificador SVM para mbc	69
Tabla 14. Tasas de clasificación de SVM con mc	79
Tabla 15. Tasas de clasificaición de SVM con mbc	80

## LISTA DE FIGURAS

	pág.
Figura 1. Localización de electrodos según sistema internacional 10-20, para el registro de EEG	25
Figura 2. Electroencefalograma normal	26
Figura 3. Sistema generalizado de reconocimiento de patrones	30
Figura 4. Espacio de separación de características	36
Figura 5. Modelo de neurona artificial	36
Figura 6. Diagrama del perceptrón multicapa, MLP	38
Figura 7. Funciones de activación de la MLP	38
Figura 8. Diagrama de red neuronal	39
Figura 9. Diagrama de la red de base radial, RBF	39
Figura 10. Funciones de activación de RBF	40
Figura 11. Transformación del espacio	41
Figura 12. Representación de las entradas de una SVM con los vectores de soporte	47
Figura 13. Localización de electrodos, para el registro de EEG en la Fundación Liga Colombiana contra la Epilepsia, capítulo Valle Helena Nader de Zaccour	50
Figura 14. Sistema de reconocimiento de patrones epileptiformes en EEG de adultos del suroccidente colombiano	57
Figura 15. Sistema de segmentación y extracción de características	58
Figura 16. Diagrama real del sistema	59
Figura 17. Imagen de la matriz de características	63

Figura 18. Matrices de imágenes por cada característica	64
Figura 19. Clasificación de la MLP con la matriz completa de toda las características, mc	65
Figura 20. Clasificación de la MLP con la matriz de mejores características, mbc	66
Figura 21. Clasificación de la RBF con mc	67
Figura 22. Clasificación de la BRF con mbc	67
Figura 23. Clasificación de la SVM con mc	68
Figura 24. Mejora en la clasificaicón de la SVM para mc	68
Figura 25. Clasificación de la SVM con mbc	69
Figura 26. Mejora en la clasificación de la SVM para mbc	70
Figura 27. ROC de la MLP para entrenamiento y validación de los datos de mc	70
Figura 28. ROC de la MLP para entrenamiento y validación de los datos de mbc	70
Figura 29. ROC de la RBF para entrenamiento y validación de los datos de mc	71
Figura 30. ROC de la RBF para entrenamiento y validación de los datos de mbc	71
Figura 31. ROC de la SVM para entrenamiento y validación de los datos de mc	72
Figura 32. ROC de la SVM mejorada, entrenamiento y validación de los datos de mc	74
Figura 33. ROC de la SVM para entrenamiento y validación de los datos de mbc	74
Figura 34. ROC de la SVM mejorada, entrenamiento y validación de los datos de mbc	75

Figura 35. Matriz de confusión de la MLP para entrenamiento y validación de mc	76
Figura 36. Matriz de confusión de la MLP para entrenamiento y validación de mbc	76
Figura 37. Matriz de confusión de la RBF para entrenamiento y validación de mc	77
Figura 38. Matriz de confusión de la RBF para entrenamiento y validación de mbc	78
Figura 39. Matriz de confusión de la SVM para entrenamiento y validación de mc	79
Figura 40. Matriz de confusión de la SVM mejorada, para entrenamiento y validación de mc	79
Figura 41. Matriz de confusión de la SVM para entrenamiento y validación de mbc	80
Figura 42. Matriz de confusión de la SVM mejorada, para entrenamiento y validación de mbc	81

## LISTA DE ANEXOS

	pág.
Anexo A. Formato de Consentimiento Informado	88
Anexo B. Edad y sexo	90
Anexo C. Segmentos de la base de Datos	91
Anexo D. Formas de Onda de Vigilia	95
Anexo E. Formas de Onda de Sueño	95
Anexo F. Formas de Onda Patológica	97

## **RESUMEN**

El trabajo que se presenta a continuación es el desarrollo de un sistema de reconocimiento de patrones para detectar Epilepsia en señales de electroencefalografía, EEG, de adultos del suroccidente Colombiano, este fue conducido en dos etapas; la primera la realización de un estudio observacional descriptivo y el segundo un estudio observacional analítico. El estudio observacional descriptivo consiste en la construcción de una base de datos, bajo la tutoría de un médico neurólogo y con la colaboración de la Fundación Liga Colombiana contra la Epilepsia, capítulo Valle Helena Nader de Zaccour. El estudio observacional analítico implementó 2 diferentes clasificadores: redes neuronales artificiales y máquinas con vectores de soporte, cada uno consta de 4 etapas; pre-procesamiento, extracción de características, selección de características y clasificación. Por último se calculó el desempeño de los clasificadores y se comparan los resultados entre ellos y los que refiere la literatura.



## INTRODUCCIÓN

Grandes enigmas han acompañado la evolución y desarrollo del ser humano a través de los tiempos. Así como muchos de estos han sido reveladas gracias a al desarrollo de las ciencias, existen otras que el trabajo arduo no ha sido suficiente para esclarecerlos completamente. Uno de ellos es el funcionamiento del cerebro. Todos sabemos que gracias a él podemos dar respuesta a muchas incógnitas; dentro de él, se generan las soluciones a todas nuestras preguntas. Ahora bien, el inconveniente es que él mismo constituye nuestra mayor interrogante. Y como si no fuera lo suficientemente fascinante ya estudiarlo por décadas y décadas en sus funciones normales, cuando éste falla, es necesario algunas veces reformular nuestras teorías y hasta en algunos casos partir desde cero. Este es el caso de la neuropatía con registro más antiguo de la historia de la humanidad, la epilepsia.

Son 50 millones de personas en el mundo las que padecen esta patología<sup>1</sup> y la incidencia de esta en un país como el nuestro, es del 12.59 por cada 1000 personas, de las cuales el 30% no están diagnosticados y en el peor de los casos son fármaco resistentes y se someten a procedimientos que en algunos pacientes son infructuosos y esto desencadena pérdida de la calidad de vida de los mismos. Desde que se evidencia su presencia en los electroencefalogramas en el año de 1895<sup>2</sup>, se ha pensado siempre en curar esta condición; como no se ha podido, ya que es idiopática, se ha pensado en controlarla y hasta el día de hoy, el control farmacológico no ha sido suficiente.

Actualmente investigadores en todo el mundo están trabajando para diseñar un controlador no farmacológico para la epilepsia. Algunos de ellos han tomado los resultados que arrojan ciertos procedimientos quirúrgicos para tratar la epilepsia, como lo es el enfriamiento focal del nodo epileptiforme por medio de solución salina a 4°C por 30 segundos, y los emplean para realizar el diseño de un dispositivo implantable; que se localice sobre el nodo y que cuando éste cense que se está presentando un ataque, genere una acción de control sobre este enfriándolo gracias al material termoeléctrico del cual está provisto el dispositivo. Sin embargo, se deben cumplir varias etapas antes de hacer esto posible; como hacer el modelado numérico del comportamiento térmico del cerebro o las pruebas de biocompatibilidad de los materiales del dispositivo, por citar algunas. Pero una de las más importantes y básicos es que el dispositivo a implantar tenga un

---

<sup>1</sup> WORLD HEALTH ORGANIZATION, INTERNATIONAL LEAGUE AGAINST EPILEPSY, INTERNATIONAL BUREAU FOR EPILEPSY, Atlas: Epilepsy care in the world. Thõnex: WHO Library Cataloguing, 2005. 93 p.

<sup>2</sup> OCAK, Hasan. Automatic detection of epileptic seizures in EEG using discrete wavelet transform and approximate entropy. Enero, 2008, vol. 36, no.1, p. 2027-2036.

sistema que le permita detectar la epilepsia por medio del análisis de las señales de EEG, con mucha exactitud, lo que comúnmente se llama detección en línea.

En este marco la realizadora de este trabajo se interesó por obtener, sólo con fines académicos, un sistema de detección de patrones fuera de línea utilizando métodos de aprendizaje de máquina, de forma tal que el trabajo realizado para cumplir el objetivo, le brindara los conocimientos suficientes para en etapas futuras convertir este proyecto de grado en un acercamiento al sistema de detección en línea. Es así como el proyecto titulado Detección de Epilepsia en señales de electroencefalografía, mediante el uso de redes neuronales artificiales y máquinas con vectores de soporte nace. Para presentarlo como se hace hoy se hizo imperativo construir primero una base de datos local y se hizo con los registros de pacientes adultos que acuden a la Fundación Liga Colombiana Contra la Epilepsia Capítulo Valle del Cauca - Helena Nader de Zaccour, esta parte constituye el estudio observacional descriptivo del trabajo. Posteriormente se hizo un estudio observacional analítico de las señales mediante un sistema de reconocimiento de patrones el cual esta compuesto por las etapas de pre-procesamiento, extracción de características, selección de características y clasificación. Esta última consistió en la implementación de 3 clasificadores, dos de ellos son de arquitecturas diferentes de una red neuronal artificial, ANN, por sus siglas en inglés y el último una máquina con vectores de Soporte, SVM, por sus siglas en inglés. En el camino a la consecución del objetivo se obtuvo una matriz de mejores características con la cual se repitió el procedimiento y se compara los resultados de esta con la de todas las características. Adicional a esto se midió el desempeño de todos los clasificadores y se obtuvo resultados aceptables en comparación con la literatura.

Se debe tener en cuenta que este proyecto realizó dos diferenciaciones importantes con respecto a trabajos similares, primero que trabajó con una base de datos local, lo que permite en general aproximar más fácilmente las soluciones a las problemáticas que aquejan a nuestra comunidad basados en datos de la misma comunidad. Segundo el trabajo es más real en comparación a la mayoría de la literatura que en este mismo se cita, ya que hace el análisis de 21 canales, tal como lo haría un experto, y no sólo 8 como la mayoría de esas investigaciones.

Con la obtención del sistema desarrollado, se aporta desde la parte social y académica, por la construcción de la base de datos que se mencionó previamente, ya que en Colombia no se había realizado esta investigación con pacientes de la región, y mientras no existan métodos validados sobre la unificación en los métodos de detección, se deben seguir planteando soluciones locales y este trabajo constituye una de estas.

Además en la parte tecnológica se abre fronteras para que se inicie o continúe investigando en este campo y se contribuye planteando otros campos de aplicación de la inteligencia computacional. Esto constituye una oportunidad más para la Universidad Autónoma de Occidente de mostrarle al mundo académico, que tiene trayectoria y que trabaja cada día para posicionarse como pionera del desarrollo en la región.

En el primer capítulo de este trabajo se presentan las bases teóricas y conceptuales que se tuvieron en cuenta para la realización del sistema. En el segundo capítulo, se encuentra de forma muy detallada la metodología que se siguió para la obtención del sistema clasificador. En el tercer capítulo se presentan los resultados que se obtuvieron de la consecución de cada una de las etapas es la metodología. Por último se presentan conclusiones y se proponen varias ideas como trabajo futuro.

## 1. MARCO DE REFERENCIA

### 1.1 MARCO DE ANTECEDENTES

La Epilepsia es la segunda enfermedad neurológica después del Accidente Cerebro-vascular, ACV, que más personas padecen en el mundo. Existen cerca de 50 millones que presentan esta patología<sup>3</sup> y de estas, 800 mil son colombianos entre niños y adultos.

Desde la observación de la actividad eléctrica cerebral en el año 1875 por el físico Inglés Richard Cantón y el posterior desarrollo del electroencefalograma en 1929 por el Psiquiatra Alemán Hans Berger<sup>4</sup>, la información que se extrae de las ondas cerebrales ha sido información invaluable para el diagnóstico y tratamiento de diferentes desórdenes neurológicos como la epilepsia. Si bien es cierto que esta patología se ha presentado durante toda la historia de la humanidad, la Epilepsia sólo se diagnosticó a partir del año 1849 gracias al médico Robert Bentley Tood<sup>5</sup>. En el año 1856 se inició la formulación de tratamientos farmacológicos y 40 años más tarde se conforma la liga contra la epilepsia, ILAE, en Budapest. Pero como se mencionó antes, es en 1929 cuando se pueden corroborar los diagnósticos con las señales de EEG.

Por su parte, las redes neuronales artificiales fueron propuestas por primera vez en el año 1943 por McCulloch y Pitts<sup>6</sup>, pero es sólo hasta 1960 que la automatización por medio de la inteligencia computacional o de sistemas inteligentes tiene auge. Ya hacia la década de los 80 muchos -por no decir la mayoría- de los procesos productivos, industriales y de manufactura, fueron transformados por la inteligencia artificial para hacer de estos procesos más eficaces. Estas herramientas fueron invadiendo todos los sectores uno a uno, arrojando resultados bastante satisfactorios que además sobrepasaban cualquier precedente. Por supuesto llegó también a la medicina y la ingeniería, ciertamente para ayudar en la detección más efectiva de muchísimas patologías, entre las que se encuentra la epilepsia.

---

<sup>3</sup> WORLD HEALTH ORGANIZATION, INTERNATIONAL LEAGUE AGAINST EPILEPSY, INTERNATIONAL BUREAU FOR EPILEPSY, Op. cit., 25 p.

<sup>4</sup> OCAK, Hasan. Op. cit., 2030 p.

<sup>5</sup> Ibíd., p. 2027.

<sup>6</sup> LOPEZ SOTELO, Jesús A. y CAICEDO BRAVO, Eduardo F. Una aproximación práctica a las redes neuronales. Santiago de Cali: Universidad del Valle, 2009, 217 p.

La primera publicación que asocia para la detección de Epilepsia a las redes neuronales, es una realizada en el año 2004 por M. Kemal Kiymik, Abdulhamit Subasi, y H. Riza Ozcalik de la universidad Kahramanmaraş Sütçü İmam, en Turquía<sup>7</sup>. En este trabajo presentan el desempeño del periodograma y métodos de análisis espectral auto-regresivos como pre-procesamiento de la señal de electroencefalografía, EEG, permitiendo la clasificación mediante Redes Neuronales Artificiales, ANNs, por sus siglas en inglés. La extracción de las características la realizaron aplicando la transformada de Fourier a la función de autocovarianza y paralelamente análisis espectral auto-regresivo, AR. Para el entrenamiento de la red utilizaron el método de backpropagation.

En diciembre del 2005, Journal of Medical Systems publica un trabajo titulado: Artificial Neural Network based epileptic detection using time-domain and frequency-domain features<sup>8</sup>; que busca hacer detección de epilepsia utilizando características en el dominio del tiempo y de la frecuencia. La extracción de estas la hacen por métodos clásicos y utilizan una red neuronal tipo ADALINE a la cual llaman Elman Network. Este es quizás hasta el momento el trabajo con redes neuronales que mejores resultados ha arrojado puesto que con Elman Network se obtiene una exactitud del 99.6% con una sola característica de entrada.

En el 2008, investigadores del Computational Neurobiology Group y National Institute of Technology Karnataka, Surathkal, Srinivasnagar en la India<sup>9</sup>, publican su trabajo sobre la detección de la epilepsia en EEG usando redes neuronales artificiales y una post-clasificación. Realizan la detección por medio de ventaneo y descomposición wavelet. Esto arroja en total 6 coeficientes y 4 parámetros; cada ventana es representada por 24 elementos. En la parte del entrenamiento de la red neuronal lo hacen mediante aprendizaje backpropagation. Sin embargo la red no es lo suficientemente sensible a los cambios en las señales que presentan actividad epileptiforme así que con algoritmos genéticos logran controlar esto, sensibilizando lo suficiente como para detectarlas. La post clasificación se realizó haciendo correlación entre los diferentes canales.

---

<sup>7</sup> KEMAL K. M., SUBASI, Abdulhamit y RIZA O. H. Neural Network with Periodogram and Autoregressive Spectral Analysis methods in detection of Epileptic Seizure. En: Journal of Medical Systems. Diciembre, 2004, vol. 28, no.6, p. 511-522.

<sup>8</sup> SRINIVASAN, V., ESWARAN, C. y SRIRAAM, N. Artificial Neural Network based epileptic detection using time-domain and frequency-domain features. En: Journal of Medical Systems Diciembre, 2005, vol. 29, no.6, p. 647-660.

<sup>9</sup> PATNAIK, L.M. y MANYAM, Ohil K. Epileptic EEG detection using neural networks and post-classification. En: Computer Methods and Programs in Biomedicine. Agosto, 2008, vol. 91, p. 100-109.

Actualmente, una de las herramientas más avanzadas en la tarea de clasificación y reconocimiento de patrones son las Máquinas con vectores de soporte, SVM, por su nombre en inglés support vector machine, propuestas por Vladimir Vapnik, matemático Ruso, en 1992<sup>10</sup>. Estas han sido utilizadas para resolver los mismos problemas en los que las redes neuronales se han desempeñado por tanto tiempo; reconocimiento de patrones, modelamiento de sistemas, filtros adaptativos, bioinformática, lingüística computacional, visión por computador<sup>11</sup>, entre otros, con la particularidad de que las se plantean para obtener el mínimo global presentando así mejores resultados.

En el 2003 Nurettin Acir y Cüneyt Güzeliş<sup>12</sup> publican tal vez el primero de los estudios que relaciona la detección de epilepsia con las SVM. En este trabajo describen un sistema compuesto de dos etapas; la primera es un filtro no lineal modificado que actúa como un pre-clasificador, que además reduce el tiempo de cómputo. La segunda etapa es una SVM que separa una de las clases en otras dos, mejorando la exactitud en la clasificación. Este trabajo es mucho más significativo que otros aquí mismo citados, ya que utiliza 19 canales, un número muy cercano al número de canales que se usa para el desarrollo del sistema de detección de epilepsia presentada en este documento. Además tiene un margen de sensibilidad y selectividad de un 90% y 88.1% respectivamente.

La revista Experts systems with applications<sup>13</sup> publica en el 2009 el trabajo hasta el momento más novedoso en el campo del reconocimiento de patrones, en el cual se usan las SVM's como clasificador, empleando la correlación cruzada entre los segmentos de EEG, "correlogramas", los cuales son empleados como características en el proceso de decisión. Esta metodología permitió tener los índices de exactitud más altos dados por una SVM hasta ese momento, 95.96%.

El más reciente de los trabajos titulado: Least Square Support Vector Machine employing model-based methods coefficients for analysis of EEG signal<sup>14</sup>, usa la

---

<sup>10</sup> BEGG, Rezaul., LAI, Daniel T.H. y PALANISWAMI, Marimuthu. Computational Intelligence in Biomedical Engineering. Boca Raton: Taylor & Francis Group, 2008. 375 p.

<sup>11</sup> CRISTIANINI, Nello., SHAW-TAYLOR, John. An introduction to Support Vector Machines: An other kernel-based learning methods. Cambridge: Cambridge University Press, 2000. p 189.

<sup>12</sup> ACIR, Nurettin y GÜZELİŞ, Cüneyt . Automatic spike detection in EEG by a two-stage procedur based on support vector machines. En: Computers in Biology and Medicine. Agosto, 2004, vol. 34, p. 561-575.

<sup>13</sup> CHANDAKA, Suryannarayana., CHATTERJEE, Amitava y MUNSHI, Sugata. Cross-correlation aid ed support vector machine Classifier for classification of EEG signals. En: Experts systems with applications. 2009, vol. 36, p. 1329-1336.

<sup>14</sup> ÜBEYLİ, Elif D. Least square Support Vector Machine employing model-based methods coefficients for analysis of EEG signals. En: Experts Systems with applications. Enero, 2010, vol. 37, p. 233-239.

máquina con vectores de soporte como clasificador, donde se replantea el problema de optimización, dividiéndolo en varios sub-problemas de mínimos cuadrados. Esto combinado con un buen proceso de extracción de características, usando la distribución de la potencia en el espacio de la frecuencia, permite un buen desempeño del sistema, donde este último es medido mediante las curvas de error, ROC, y la matriz de confusión, métodos muy fáciles de interpretar y muy confiables, los cuales arrojan resultados de exactitud del 95% para ese sistema.

En conclusión, en Colombia existen muy pocos registros de estudios sobre la detección automatizada de esta neuropatía o el seguimiento de su tratamiento. En la mayoría de los casos los procesos nombrados anteriormente se realizan utilizando las señales de EEG analizadas por el médico experto en la patología y se administran fármacos para su tratamiento según el estudio de toda la historia clínica. Aunque un sin número de equipos que hay en los centros asistenciales en el país, tienen módulos que podrían aproximarse a realizar la detección automática de la actividad Epileptiforme utilizando la CWT, los profesionales en la salud son reacios a utilizarlos por los pobres resultados que han mostrado en esta labor sumado a esto el desconocimiento de la evolución y versatilidad de las herramientas computacionales de hoy día son factores que hacen que estas condiciones de poca o nula investigación se mantenga.

Nuestra localidad no es la excepción y nada se encuentra publicado hasta el momento que relacione la detección de epilepsia con este par de métodos, lo que supone que el trabajo aportará a la comunidad con los resultados que arroje este estudio.

## **1.2 MARCO CONCEPTUAL**

A continuación se encuentra la información más relevante sobre la patología con la que se relaciona la tarea de reconocimiento de patrones objetivo de este proyecto, si desea ampliar un poco más la información al final se encuentra un apéndice referente a la neuroanatomía y neurofisiología.

**1.2.1 Epilepsia.** Se define como un trastorno neuronal crónico, donde la persona que padece esta patología, sufre de episodios de descargas eléctricas bruscas, espontáneas, recurrentes, incontrolables y sostenidas; llamados convulsiones, ataques o crisis epileptiformes. Infortunadamente estas no definen si una persona es epiléptica o no, ya que estas pueden producirse por otras razones, tales como fiebre. Por tanto, para el diagnóstico final sobre si una persona padece esta patología, se debe hacer una historia clínica detallada, un EEG y una Imagen de

Resonancia Magnética, MRI, (por sus siglas en ingles, Magnetic Resonance Image) en casos muy particulares.

Se debe distinguir claramente entre crisis epiléptica, que es aquel trastorno funcional de las células neuronales de un área específica del cerebro, y la epilepsia, que es la reunión de estas crisis. Las crisis pueden ser parciales o generalizadas. Las primeras; parciales, hacen referencia a un área determinada del cerebro, mientras que las segundas lo hacen a muchas pequeñas áreas en el cerebro, que al activarse al mismo tiempo, comúnmente se les llama convulsiones. Las personas con epilepsia pueden presentar diversos síntomas que dependen de las crisis; unos pueden ser severos o notorios y otros pasar casi inadvertidamente.

**1.2.2 Electroencefalografía.** Para comprender este término se deben tener claros dos aspectos importantes, sin los cuales no habría cabida para este concepto. Primero, que gracias a la ocurrencia de un fenómeno llamado electrogénesis cortical; aquel que se presenta cuando el tejido cerebral por su actividad normal genera unos potenciales eléctricos: excitatorios o inhibitorios que se operan entre si, dando origen a las ondas cerebrales, y segundo, a que estos fenómenos, descritos anteriormente, se encuentran focalizados en unos puntos que se denominan generadores. Se puede entender a la electroencefalografía como una técnica que realiza el registro de las señales unidimensionales provenientes de esos generadores; para esto se hace uso de un equipo llamado electroencefalógrafo.


El electroencefalógrafo está provisto de un sistema de adquisición y otro de procesamiento. El de Adquisición consta de un cierto número de canales, a los cuales se les asocia los electrodos; que colocados sobre el cuero cabelludo de forma ordenada en ciertas partes de la cabeza, brindan información de ciertos sectores del cerebro. El de procesamiento es una interfaz que opera entre si los potenciales que le entrega cada canal; a esto se le llama derivaciones, las cuales están ligadas a la configuración para la visualización que se utilice para cada registro.

Cuando se habla de configuraciones se refiere al posicionamiento de los electrodos con un orden en particular que permiten visualizar diversos conjuntos de derivaciones y cada grupo de conjuntos llevan el nombre de montaje.

Una de las configuraciones más comunes para realizar el registro de las EEG es el sistema internacional diez-veinte, mostrado en la Figura 1.



**Figura 1. Localización de electrodos según sistema internacional 10-20, para el registro de EEG**



**1.2.2.1 Montajes.** Unos electrodos puestos en la disposición anterior permiten visualizar al menos unos 43 montajes. Montaje estrictamente es sólo la forma en la que se presenta la información del electroencefalograma. Existen 2 tipos y sus principales características y cualidades para la clasificación se presentan resumidas en el Cuadro 1.

**Cuadro 1. Clasificación de montajes para registro de señales de EEG**

BIPOLAR	REFERENCIAL
Es la comparación de la tensión entre 2 electrodos, normalmente adyacentes que se encuentran en una secuencia.	Es la comparación de la tensión entre cada electrodo y un electrodo inactivo, este último se posiciona en el músculo mastoideo, en la oreja o el promedio de muchos electrodos también puede hacer las veces de referencia.
Menos susceptible al ruido.	Mucho más útil para la visualización de descargas generalizadas <sup>15</sup> .
Reduce el número de canales a analizar en una tarea de clasificación <sup>16</sup> .	Puede mostrar las amplitudes de los potenciales de forma más real <sup>17</sup> .

<sup>15</sup> TATUM, William O. Handbook of EEG interpretation. United States of America: Demos Medical Publishing, 2008. 275 p.

<sup>16</sup> AARABI, Ardalan., WALLOIS, Fabrice., y GREBE, Reinhard. A multistage knowledge-based system for EEG seizure detection in newborn infants. En: Clinical Neurophysiology. Agosto, 2008, vol. 118, p 2781-2797.

<sup>17</sup> BLUM, Andrew S. y RUTKOVE, Seward B. The Clinical Neurophysiology Primer. New Jersey: Humana Press Inc, 2007. 526 p.

Dentro de las dos clases de montajes presentados anteriormente, existen 3, que caben dentro de esa clasificación y son los más utilizados por los expertos, se presentan en el cuadro 2. Estos se utilizaron como soporte para la construcción de la base de datos de este trabajo.

**Cuadro 2. Montajes más comunes**

Ipsi Ear	Doble B	CZ Ref
La referencia son los electrodos A1 y A2 que son oreja izquierda y oreja derecha respectivamente, es muy susceptible a ruido.	Se pueden observar las zonas fronto-temporales y las centrales.	Tiene como referencia el electro CZ y con este montaje se puede analizar todo el cerebro.

Un ejemplo de cómo se visualiza un EEG normal en la derivación de Ipsi Ear se muestra en la Figura 2.

**Figura 2. Electroencefalograma normal**



**1.2.2.2 Tipos de trazado.** Una vez los registros al ser evaluados por el médico experto, pueden ser denominados normales o anormales. Donde la anormalidad es un término que describe la condición en la que se presentan una o varias de las siguientes condiciones:

- **Trazado lento.** Se le denomina así porque las ondas alfa que se presentan durante el estado de vigilia con los ojos cerrados que tienen una frecuencia de 8 a 13 Hz generalmente en personas de 3 meses de edad en adelante, se presentan con una frecuencia menor o incluso se puede registrar solo actividad theta durante la mayor parte del tiempo que dura el trazado.

- **Brotos paroxísticos.** Se le llama así a toda aquella actividad cerebral que aparece de repente durante el trazado; es decir que si una persona se pone somnolienta la aparición esporádica de ondas de sueño y alfa son de naturaleza paroxística. Sin embargo si existe alguna patología, son brotes paroxísticos todas aquellas anomalías que en el trazado presentan mayor amplitud que las ondas normales de vigilia y sueño. Pueden presentarse focalizados, generalizados o focalizados pero generalizan; es decir que afecta el ritmo normal de otras áreas del cerebro. En ocasiones modifican el trazo de fondo y si es así, son más graves aún.

- **Brotos de tipo epileptiforme.** Son aquellos que por su morfología son propios de la Epilepsia como los punta-onda, polipunta-onda, etc.

**1.2.2.3 Tipos de onda.** Los registros de un EEG siempre van a mostrar diferentes tipos de ondas, en los cuadros 3, 4 y 5 se muestran sus principales características.

En el cuadro 3 están las llamadas ondas fundamentales<sup>18</sup>, con frecuencias que oscilan entre los 0.5 Hz y los 22 Hz.

Existen otras ondas que solo se presentan en estadios de sueño... véase cuadro 4...

Y finalmente otras ondas propias de la patología en la que se centra este trabajo...véase cuadro 5...

**Cuadro 3. Tipos de onda de vigilia**

<b>Alfa</b>	<b>Beta</b>	<b>Delta</b>	<b>Theta</b>
Frecuencia de 8 Hz - 13 Hz.	Frecuencia de 14 Hz - 28 Hz.	Frecuencia de 0.5Hz - 3.5Hz.	Frecuencia de 3.5 Hz – 7 Hz.
Amplitud menor de 15 $\mu$ V <sup>19</sup> .	Amplitud menor de 20 $\mu$ V <sup>20</sup> .	Amplitud mínima de 75 $\mu$ V <sup>21</sup> .	Amplitud menor de 15 $\mu$ V <sup>22</sup> .

<sup>18</sup> BRONZINO, Joseph D. Biomedical Engineering Handbook. 2 ed. Boca-Raton: CRC Press LLC, 2000. 3187 p.

<sup>19</sup> TATUM, Op. cit., p. 125

<sup>20</sup> Ibíd., p. 126

<sup>21</sup> DURKA, Piotr. Matching pursuit and unification in EEG analysis. Norwood: Artech House Inc. 2007, 184 p.

<sup>22</sup> TATUM, Op. cit., p. 127

Se genera en las regiones occipitales.	Se genera en regiones centrales frontales.	Se genera en hemisferio derecho.	Se genera en regiones frontocentrales.
Es llamada la frecuencia natural del cerebro.	Estado de alerta máximo.	Se presentan cuando hay sueño profundo o meditación.	Aparece cuando la persona está somnolienta y se percibe generalizada.
Aparece con los ojos cerrados, en estado de vigilia.	La amplitud aumenta si existen tumores o defectos en el hueso.	Los tumores se evidencian como ondas de este tipo.	Es anormal que se presenten brotes de este tipo durante la somnolencia.
-	Medicamentos como el fenobarbital o el rivotil la inducen.	-	Medicamentos como el valium y el midazolam la inducen.

Normalmente la onda  $\alpha$  es la única que debe aparecer cuando una persona sana comienza a descansar, ya que cuando se padece la patología de estudio aparecen las ondas  $\delta$  y  $\theta$ .

**Cuadro 4. Tipos de onda de sueño**

Husos de sueño	Vertex	Complejos K	REM
11 Hz – 15 Hz <sup>23</sup> .	Aislados	Aislados	3 – 5 Hz <sup>24</sup>
0.5–1 s de duración <sup>25</sup> .	50-200 ms de duración <sup>26</sup> .	Menos de 500 ms <sup>27</sup> .	-
Amplitud de 30 $\mu$ V <sup>28</sup>	Amplitud >100 $\mu$ V	Amplitud >75 $\mu$ V	-

<sup>23</sup> DURKA, Op. cit., p. 56

<sup>24</sup> TEJEIRO MARTÍNEZ, Jose. EEG Normal. Barcelona: Viguera Editores, 2010[consultada el día 10 de julio]. Disponible en internet: [www.viguera.com/pdf/muestra/8485424557.pdf](http://www.viguera.com/pdf/muestra/8485424557.pdf)

<sup>25</sup> SÖRNMO, Leif. y LAGUNA, Pablo. Bioelectrical signal processing in cardiac and neurological applications. Academic Press, Elsevier, 2005. 688 p.

<sup>26</sup> EEG Normal Op. cit., Disponible en internet: [www.viguera.com/pdf/muestra/8485424557.pdf](http://www.viguera.com/pdf/muestra/8485424557.pdf)

<sup>27</sup> Ibíd., Disponible en internet: [www.viguera.com/pdf/muestra/8485424557.pdf](http://www.viguera.com/pdf/muestra/8485424557.pdf)

<sup>28</sup> BLUM, Op. cit., p 319

No se visualizan en temporales.			Se caracteriza por presentar un rápido movimiento ocular.
Característica de la fase II de sueño.	Característica de la fase I y II de sueño <sup>29</sup> .	Característica de la fase II y III de sueño.	Característica de la fase III y IV de sueño.
Origen en las regiones centrales con reflejo en las frontales <sup>30</sup> .	Aparece en las regiones fronto-centrales.	Aparece en las regiones fronto-centrales.	Apare en la regiones centrales <sup>31</sup> .
Simétrico, Sincrónico y Bilateral.	Asimétrico, Sincrónico, es Bilateral pero en occipitales puede ser unilateral <sup>32</sup> .	Es la combinación superpuesta de los husos de sueño con las ondas vertex <sup>33</sup> .	Tiene forma de "dientes de sierra" <sup>34</sup> .
Puede ser inducido por estímulo auditivo <sup>35</sup> .	-	Puede ser inducido por estímulo auditivo <sup>36</sup> .	Se asocia normalmente con la acción de soñar <sup>37</sup> .

#### Cuadro 5. Tipos de onda epileptiformes

Puntas o Espigas	Punta-Onda	Poli-Punta Onda
Son Ondas de gran amplitud	Se les llama así, porque la espiga se encuentra acompañada de una onda, que puede ser lenta o aguda.	Son 2 espigas una seguida de la otra y luego viene la onda, aguda o lenta.

Además de las ondas que se nombraron anteriormente existen detalles que son importantes para tener en cuenta a la hora de analizar las señales, como los siguientes:

<sup>29</sup> TATUM, Op. cit., p. 130

<sup>30</sup> Ibíd., p. 130

<sup>31</sup> EEG Normal Op. cit., Disponible en internet: [www.viguera.com/pdf/muestra/8485424557.pdf](http://www.viguera.com/pdf/muestra/8485424557.pdf)

<sup>32</sup> TATUM, Op. cit., p. 131

<sup>33</sup> Ibíd., p. 131

<sup>34</sup> EEG Normal Op. cit., Disponible en internet: [www.viguera.com/pdf/muestra/8485424557.pdf](http://www.viguera.com/pdf/muestra/8485424557.pdf)

<sup>35</sup> SANEI, Saeid. y CHAMBERS, J.A. EEG Signal Processing. West Sussex: John Wiley and Sons, Ltd, 2007. 289 p.

<sup>36</sup> TATUM, Op. cit., p. 275

<sup>37</sup> SANEI, Op. cit., p. 143


La hiperventilación un procedimiento de activación en donde la persona inspira aire por la nariz y expira este por la boca a una frecuencia mayor que la respiración normal de forma tal que no se hagan inspiraciones profundas en las cuales el aire llega hasta la base de los pulmones realizando intercambio gaseoso casi completo, por el contrario el aire solo llega hasta la parte superior de los pulmones provocando una saturación de  $\text{CO}_2$  en sangre. Durante el examen de electroencefalografía, en los niños tiende a reflejarse como un aumento generalizado en la amplitud del trazado y es totalmente normal hasta los 15 años de edad. De ahí en adelante un aumento en la amplitud se considera anormal e indica que el paciente podría presentar en ese examen u otras ondas tipo epileptiformes y realizando más exámenes como este y evaluando su historia clínica se puede determinar si el paciente presenta epilepsia.

Existen otras ondas como el ritmo *mu*, que puede utilizarse como realimentación en el entrenamiento para saber si los medicamentos para la epilepsia han sido efectivos.

### 1.3 MARCO TEÓRICO

**1.3.1 Sistema generalizado de reconocimiento de patrones.** Es un proceso lógico y ordenado de pasos o etapas mediante el cual se puede asegurar que el proceso de clasificación o la tarea de reconocimiento de patrones, se va realizar exitosamente y no por el uso de un determinado clasificador sino por el sistema integrado. Muchos investigadores<sup>38</sup>, plantean varios esquemas, pero se puede sintetizar en las etapas que ilustra la Figura 3.

**Figura 3. Sistema generalizado de reconocimiento de patrones**



Este sistema básicamente consiste en tener 4 fases. La primera es la obtención de una señal preprocesada,  $S_i \in \mathbb{R}^n$ . La segunda es la extracción de sus principales características, la tercera es la selección de aquellas que son más

<sup>38</sup> OROZCO, Mauricio. Selección Efectiva de características wavelet en la identificación de bioseñales 1-D y 2-D usando algoritmos genéticos. Trabajo de grado Magíster en Ingeniería-Automatización Industrial. Manizales. Universidad Nacional de Colombia. Facultad de Ingeniería y Arquitectura. Departamento Ingeniería Eléctrica, Electrónica y Computación. 2005. 80 p.

relevantes para nuestra tarea y colocarlas finalmente como entradas de nuestro sistema clasificador.

**1.3.2 Pre-procesamiento.** Es la preparación de las señales mediante la aplicación de filtros digitales y/o diversas técnicas, según se adapten al comportamiento de cada señal. Es imprescindible conocer la señal muy bien para determinar con cual método se va a eliminar el ruido y cual es el mejor para una determinada aplicación. Las señales de EEG, al ser registradas como cualquier otra señal electrofisiológica, presenta ciertas características propias de su naturaleza o del instrumento de captura, los cuales son determinantes a la hora de realizar un análisis de estas, por ejemplo; el ruido de red o movimiento muscular que impide la buena visualización y la correcta interpretación de la información<sup>39</sup>. Los métodos que más utilizan en EEG son:

**1.3.2.1 Filtros Digitales.** Pueden ser tipo FIR o IIR, donde los primeros al tener ventanas del mismo tamaño no se ajustan a las especificaciones de no-periodicidad de la señal de EEG, son de fase lineal, más estables y necesitan un orden elevado. Mientras los IIR pueden diseñarse con especificaciones de orden mucho menores que los FIR y además las especificaciones de diseño son pocas, lo que representa un diseño de baja complejidad computacional.

**1.3.2.2 Periodograma.** Es un método no paramétrico que consiste en el cálculo de la densidad de potencia en el espacio de Fourier.

**1.3.2.3 Análisis espectral auto-regresivo.** Análisis espectral paramétrico en el que se hace el modelado de una secuencia de datos, minimizando el error y obteniendo unos coeficientes de reflexión.

**1.3.2.4 Transformada de Fourier.** Es una transformación del espacio del tiempo al de la frecuencia, basado en la hipótesis de que una señal es la combinación lineal entre los coeficientes de Fourier y sus ondas sinusoidales de diferentes frecuencias. Por eso al aplicarla sobre una señal esta brinda información del comportamiento de la señal en el espacio de la frecuencia.

**1.3.2.5 Transformada Discreta Wavelet, DWT.** Es también una transformación del espacio del tiempo al de la frecuencia. Es empleada debido a que representa de forma efectiva el comportamiento en tiempo-frecuencia de las señales, lo cual es de gran interés para el análisis de señales no estacionarias, ya que captura las

---

<sup>39</sup> SÖRNMO, Op. cit., p. 514

discontinuidades y repetición de patrones, donde fallan otros enfoques de procesamiento de señales.

**1.3.3 Procesamiento de señales.** El desempeño de los sistemas de clasificación y/o reconocimiento de patrones dependen en gran medida de la separabilidad de los datos en un espacio de características, lo que hace prioritario un adecuado procesamiento de la señal, del cual se extraen y evalúan las características que aportan al aumento del margen de separación entre grupos.

**1.3.3.1 Extracción de características.** Determina la información necesaria para la segmentación de clases, así se hace una buena tarea de reconocimiento. El desempeño que obtenga un clasificador, -ANN's y SVM's- depende de las etapas de extracción y selección de características<sup>40</sup>.

A continuación se listan las características más comunes de las señales de EEG<sup>41</sup>.

- Amplitud de ondas.
- Duración de onda.
- Medidas de histograma.
- Momentos de onda o desviación estándar. Es una medida de dispersión, que se deriva de calcular la raíz cuadrada de la varianza<sup>42</sup>. Se calcula como se muestra en la ecuación 8.

$$\sqrt{s} = \sqrt{\frac{\sum_{i=1}^n (x_i - \mu)^2}{n - 1}}, \quad (8)$$

---

<sup>40</sup> SCHÖLKOPF, Bernhard. y SMOLA, Alexander J. Learning with kernels: Support Vector Machines, Regularization, Optimization and Beyond. United States of America: The MIT Press, 2002, 626 p.

<sup>41</sup> MARQUES DE SÁ, Joaquín P. Pattern Recognition: Concepts methods and applications. Portugal: Springer, 2001, 317 p.

<sup>42</sup> Ibíd., 183 p.



donde  $s$  es la varianza,  $\bar{x}$  es promedio de los valores evaluados y  $n - 1$  los grados de libertad.

- Morfología de onda o simetría.
- Cruces por cero.
- Picos de autocorrelación.
- Picos espectrales o transformada de Fourier.
- Media. La media aritmética se define como una medida de tendencia central, que consiste en hacer la sumatoria de todos los valores de una muestra y se dividen por el número de valores totales<sup>43</sup>. De manera formal se puede expresar como se muestra a continuación en la ecuación 7.

$$\mu = \frac{\sum_{i=1}^N x_i}{N}, \quad (7)$$

donde  $N$  es el número total de componentes,  $x_i$  es cada uno de los valores.

- Curtosis. Es una medida de forma, en donde el grado de rugosidad de una probabilidad o función de densidad cerca de su centro se puede expresar como sigue<sup>44</sup>:

$$k = \frac{E[(X - \mu)^4]}{\sigma^4 - 3}, \quad (9)$$

donde  $E[X]$  es la media,  $\sigma^4$  es un factor de estandarización.

- Asímetría. Es una medida de forma, en donde se mide la distribución simétrica y continua alrededor de la media  $\mu$ <sup>45</sup>. Esto da lugar a los coeficientes de asimetría que se calculan con la siguiente expresión:

---

<sup>43</sup> WAYNE W, Op. cit., 183 p.

<sup>44</sup> MARQUES DE SÁ, Joaquin. Applied statistics: Using SPSS, STATISTICA, MATLAB and R. Portugal: Springer, 2007. 505 p

$$\gamma = \frac{E[(X - \mu)^3]}{\sigma^3}. \quad (10)$$

Según el trabajo Ardalan Aarabi<sup>46</sup>, muchas de estas características se pueden ordenar en 5 grupos:

- Características en el dominio del tiempo. Que se extraen directamente de las señales.
- Características en el dominio de la frecuencia. Que se extraen directamente de las señales.
- Coeficientes auto-regresivos. Se calculan los coeficientes para la señal y a estos coeficientes se les puede aplicar diferentes métodos como los mencionados anteriormente.
- Características wavelet. El mismo procedimiento que para coeficientes auto-regresivos.
- Características cepstrales. Se calcula de la señal unos coeficientes a los cuales se les extraen las diferentes características. Los Coeficientes Cepstrales, CC, se definen como el logaritmo de la transformada discreta de Fourier, DFT, donde esta es definida por la siguiente ecuación:

$$\hat{x}(n) = \mathcal{T}_F\{x(k)\},$$

$$\hat{x}(n) = \sum_{k=0}^{N-1} x(k)e^{j\frac{2\pi kn}{N}}, \quad (11)$$

donde  $\hat{x}(n)$  es la DFT de  $x(k)$ ,  $\mathcal{T}_F\{\cdot\}$  es el operador de transformación y  $K = 0, \dots, N - 1$ <sup>47</sup>. Si se le aplica el logaritmo en base 10 a  $\hat{x}(n)$  y luego se le aplica el

---

<sup>45</sup> MARQUES DE SÁ, Op. cit., 221 p.

<sup>46</sup> AARABI, Ardalan., WALLOIS, Fabrice., y GREBE, Reinhard. Automated neonatal seizure detection: A multi-state classification systems through feature selection based on relevance and redundancy analysis. En: Clinical Neurophysiology. Diciembre, 2005, vol. 117, p. 328-340.

<sup>47</sup> TEJEIRO MARTÍNEZ, Jose. EEG Normal. Barcelona: Viguera Editores, 2010[consultada el día 10 de julio]. Disponible en internet: [www.viguera.com/pdf/muestra/8485424557.pdf](http://www.viguera.com/pdf/muestra/8485424557.pdf)

operador de transformación inverso,  $\mathcal{T}_F^{-1}\{.\}$ , se obtienen los coeficientes Cepstrales,  $c(k)$ , de la siguiente forma

$$c(k) = \mathcal{T}_F^{-1}\{\log_{10}|\mathcal{T}_F\{x(k)\}|\}, \quad (12)$$


Por tanto primero se debe realizar la transformada de Fourier a las señales y posteriormente el cálculo del logaritmo.

**1.3.3.2 Selección de características.** De un gran conjunto de características que se obtienen de la extracción, existen unas que son más relevantes para la clasificación. El objetivo principal de esta etapa es escoger cuales utilizar, esto para asegurar dos aspectos, primero que no haya redundancia en los datos; es decir que sean linealmente independientes y segundo que sean relevantes; por lo cual se busca que representen bien la muestra de estudio. Al asegurar estas dos condiciones se esta evitando tener un problema muy frecuente como es “la maldición de la dimensionalidad”, en el cual la tarea de clasificación se vuelve más difícil al aumentar la dimensión del espacio de características. La herramienta más versátil y con mejores resultados en el análisis de las EEG es el Análisis de componentes Principales, PCA.

Cuando se construye un espacio de características a partir de los datos, se trazan unos ejes sobre los cuales es probable que estos se muestren correlacionados, sin embargo al mover estos ejes, se permite que muchas características ya no se encuentren tan correlacionadas unas con otras, así se puede desestimar a algunas e ir reduciendo la dimensión de este espacio. Por lo tanto a esta actividad de ir rotando se le denomina PCA.


**1.3.4 Clasificación y reconocimiento de patrones.** Es el proceso de encontrar en un espacio de características una función que separe las distintas clases que la componen. Para el desarrollo de este trabajo se utilizan dos tipos de Redes Neuronales Artificiales, por sus siglas en ingles ANN, *Artificial Neural Network* y las Máquinas con vectores de soporte, SVM por sus siglas en ingles, *Support Vector Machine*. En la figura 4 se muestra un ejemplo de un espacio de características en donde existen 4 clases separadas por diversas funciones. El objetivo principal de un clasificador es escoger el mejor hiper-plano de separabilidad.

**Figura 4. Espacio de separación de características**



Para este trabajo se tiene entonces que las redes neuronales artificiales, ANN's, por sus siglas en inglés, son una herramienta computacional bio-inspirada, en la que se tiene como base, que las neuronas biológicas se comunican con otras por medio de la sinapsis; en la parte computacional esto es traducido a un peso sináptico que influye en la señal de entrada como una ganancia, haciendo que esta por medio del peso cambie el comportamiento de la red neuronal. En la Figura 5 se muestra el esquema general de una neurona artificial.

**Figura 5. Modelo de neurona artificial**



La neurona artificial se caracteriza por tener unas entradas  $X_i$ , una o varias salidas  $Y_j$  y un peso de tendencia  $b_j$ , donde cada entrada tiene asociado un peso  $W_{ij}$  relacionándola con las siguientes neuronas. Es posible calcular la entrada neta de cada neurona perteneciente a la red, sumando la multiplicación de sus

entradas con sus respectivos pesos asociados y adicionando el peso de tendencia de la siguiente forma:

$$N_j = \sum_i X_i * W_{ij} + b_j, \quad (1)$$

donde  $N$  es la entrada neta, la cual permite encontrar la salida neta de la red , evaluándola en una función de activación así:

$$y = Fact(N), \quad (2)$$

donde  $Fact(.)$  es la función de activación, la cual puede ser de diferentes tipos: escalón, escalón bipolar, sigmoideal, tangente sigmoideal, logarítmica, lineal, entre otras<sup>48</sup>, donde algunas de estas se muestran en la Figura 7.

El entrenamiento de una red consiste en encontrar los pesos  $W_{ij}$  y los pesos de tendencia  $b_j$  , mediante algoritmos de optimización multivariable. Estos algoritmos pueden basarse o no en gradiente; algunos como gradiente descendente, gradiente conjugado, paso descendente o técnicas de programación matemática, se encuentran el primer grupo, mientras que en el segundo se encuentran las estrategias evolutivas o técnicas metaheurísticas<sup>49</sup>.

Las ANN's se pueden clasificar mediante su arquitectura o su tipo de entrenamiento. Según el tipo de entrenamiento se encuentran el Supervisado y el no supervisado. Entre las arquitecturas existen las monocapa, multicapas y recurrentes.


**1.3.4.1 Red neuronal, perceptrón multicapa, MLP.** En contraste con su antecesora, la monocapa, esta permite dar solución a problemas que no son linealmente separables. Conserva su capa de entrada, su capa de salida y además puede tener varias capas de neuronas de procesamiento a las cuales agregan grados de libertad en la búsqueda del hiper-plano de separabilidad y son llamadas capas ocultas, como se muestra en la Figura 6.

---


<sup>48</sup> LOPEZ SOTELO, Op. cit., p. 9.

<sup>49</sup> MEYER-BÄSE, Anke. Pattern Recognition for Medical Imaging. San Diego: Elsevier Inc, 2004. 385 p.

**Figura 6. Diagrama del perceptrón Multicapa.**



**Figura 7. Funciones de activación de la MLP**



Las funciones de activación mostradas en la Figura 7, permiten el aprendizaje basado en gradiente, el único inconveniente de la implementación de esta red es el entrenamiento de las capas ocultas y para solucionarlo se usa el método de Back Propagation.


El aprendizaje de todas las redes está asociado con la modificación de los pesos sinápticos mediante un proceso iterativo. Computacionalmente la red cumple con las etapas que se muestran en la Figura 8, para procesar satisfactoriamente las señales.

**Figura 8. Diagrama de red neuronal**




**1.3.4.2 Red neuronal de base radial, RBF.** Surgió conceptualmente como una red neuronal de regularización que daba solución al problema de interpolación. Su arquitectura multicapa unidireccional y su aprendizaje híbrido son las que le permiten su buen desempeño, simplicidad y velocidad en el aprendizaje. En la capa oculta el aprendizaje es no supervisado y la función de activación en contraste con una MLP, es cambiada por una función gaussiana. Generalmente esta función es la que se aplica para medir la distancia euclídea entre las neuronas de la capa oculta y las características o neuronas de entrada; donde la desviación estándar de cada neurona mide la dispersión de la red. En la capa de salida el aprendizaje es supervisado y la función de esta neurona es lineal. En las Figuras 9 y 10 se muestran la forma general de una RBF y las funciones de activación respectivamente.

**Figura 9. Diagrama de la red de base radial, RBF**



**Figura 10. Funciones de activación de RBF**



**1.3.4.3 Máquinas con Vectores de Soporte, SVM.** Propuestas como se conocen hoy día por Vapnik<sup>50</sup> en 1992, estas máquinas de aprendizaje son un compendio de diferentes técnicas de aprendizaje de máquina, propuestas desde los años 60 por muchos investigadores<sup>51</sup>.

Estas están basadas en un principio inductivo, conocido como minimización del riesgo estructural, SRM. Donde se tiene en cuenta la finitud de los datos de entrenamiento para construir espacios de aproximación anidados sobre estos. Al hacerse un mapeo sobre estos espacios se da solución a problemas convexos, que no presentan mínimos locales y esto convierte a las SVM's en un sistema extremadamente eficiente<sup>52</sup>.

La condición anterior se debe en concreto a que obedece a los 2 principios que se muestran en el cuadro 6.

<sup>50</sup> BEGG, Op. cit., p. 289

<sup>51</sup> CRISTIANINI, Op. cit., p. 10

<sup>52</sup> Ibid., p. 7




**Cuadro 6. Principios de una SVM**

Teoría de la generalización	Teoría de la optimización
Es una guía clara de cómo controlar la capacidad y prevenir el sobre-entrenamiento del sistema; para controlar el margen de separación de los hiperplanos.	La cual provee las técnicas matemáticas necesarias para encontrar los hiperplanos de separación óptimos.

Suponga que se tiene un conjunto de datos  $D$  representados en un espacio de características de orden  $n$ , estos pertenecen a diferentes clases; sin embargo en un primer momento no se puede asociar un objeto o dato a alguna clase en particular. Para poder asociarlo, la SVM realiza sobre este espacio una transformación mediante una función  $\phi(.)$ , la cual tiene como objetivo, facilitar la separación lineal entre clases.

Por ejemplo en la Figura 13 se muestra la influencia de una función de transformación, que al ser aplicada sobre el espacio de entrada permite la separación lineal de las clases.

**Figura 11. Transformación del espacio**



**Fuente:** BETANCOURT, Gustavo A. Las Máquinas de Soporte Vectorial, (SVMs). En: Scientia et Technica. Abril, 2005, vol. 10, no. 27, p. 67-72.

La tarea de separar clases, se resuelve mediante el planteamiento de un problema de optimización convexa el cual permite maximizar el margen,  $m$ , asegurando un máximo global. Para comenzar se enmarca el problema en la maximización del siguiente sistema geométrico:

$$\begin{aligned} \langle w * x^+ \rangle + b &= +1, \\ \langle w * x^- \rangle + b &= -1, \end{aligned} \quad (3)$$


donde  $w$  son los pesos que maximizan  $m$ ,  $x$  son los datos de entrada y  $b$  son los pesos de tendencia.

De esta forma se puede estimar la salida de una SVM utilizando la siguiente expresión:

$$y = \sum_{i=1}^N w_i \varphi(x) + b, \quad (4)$$

donde  $y$  es la salida del clasificador y  $\varphi(.)$  es la función kernel, la cual modifica el espacio de características, permitiendo la separación lineal en este nuevo espacio. El resultado son clases diferenciadas mediante un hiperplano de separación, el cual conserva un margen que depende de los valores más cercanos a ese hiperplano y a estos se les llama vectores de soporte...véase Figura 14... Sin embargo dependiendo de los intereses se puede modificar este margen mediante el uso del kernel  $\varphi(.)$ , como ya se comentó anteriormente. El más usado para el procesamiento de señales de EEG es el kernel gaussiano<sup>53</sup>, mostrado en la Figura 10 a.

**Figura 12. Representación de las entradas a una SVM con los vectores de soporte**



**Fuente:** BIOINFORMATICS TOOLBOX. Cali: Universidad Autónoma de Occidente. MatLab® R2009a.

<sup>53</sup> ACIR, Nurettin. Op. cit., p. 564

En resumen para las ANN's se tiene funciones de activación que permiten tener respuesta de la red, en SVM's tenemos funciones de transformación. La forma en la que una red neuronal con sus capas ocultas brindan a la red una mayor capacidad de decisión, en las SVM's son los kernel y las herramientas para resolver el problema de optimización convexo.

Si se quisiera seguir mejorando los resultados existen diferentes mecanismos que permiten realizar esta tarea. Uno es el planteamiento mediante la optimización suave del margen; el cual permite añadir una tolerancia en la búsqueda de los vectores de soporte.

**1.3.5 Evaluación de desempeño.** Cuando ya se ha terminado la tarea de reconocimiento de patrones es de suma importancia evaluar que tan bien se realizó el trabajo de forma cuantitativa, es decir, aplicarle al sistema una serie de indicadores que ayuden a juzgar y además a complementar el trabajo, puesto que con resultados no muy favorables se puede modificar una o algunas de la etapas anteriores para obtener mejores resultados.

**1.3.5.1 Errores de clasificación.** Lo componen el error de entrenamiento y el error de prueba que obtiene cada clasificador. Se presenta como un valor entre 0 y 1, entre más se acerque a cero el valor; el error no solo es menor sino que indica además que se obtuvo un buen desempeño.

**1.3.5.2 Características operativas del receptor.** ROC, por sus siglas en inglés, son una herramienta que muestra visualmente el desempeño de los clasificadores mostrando curvas para entrenamiento, prueba y test, en donde una curva entre más se parezca a un escalón unitario mejor es el desempeño en la determinada fase.

**1.3.5.3 Exactitud.** En la clasificación es el factor entre el número de decisiones correctas sobre el número total de casos<sup>54</sup>.

**1.3.5.4 Validación cruzada.** Se hace partición aleatoria de los datos de entrenamiento, prueba, validación y se utilizan para realizar la clasificación, proporcionándole a la tarea de clasificación más objetividad.

---

<sup>54</sup> ÜBEYLİ, Op. cit., p. 234

**1.3.5.5 Matriz de confusión.** Una herramienta que permite una fácil interpretación de los errores de clasificación, ya que compara la salida del clasificador con los valores objetivos en un arreglo de filas y columnas en donde la diagonal principal muestra los valores relevantes con respecto a la precisión del proceso.

**Figura 14. Matriz de confusión**

VN	FP
FN	VP

**1.3.5.6 Indicadores.** Durante el desarrollo del trabajo se desea obtener diversos tipos de resultados, que pueden ser falsos o verdaderos. Para poder comprender mejor como se realiza el cálculo del desempeño se tendrá como premisa lo siguiente:

- Un resultado verdadero positivo,  $vp$ , es aquel que el sistema clasificador determina como epileptiforme y el experto también<sup>55</sup>.
- Un resultado verdadero negativo,  $vn$ , es aquel que el sistema clasificador determina como no epileptiforme y el experto también.
- Un resultado falso positivo,  $fp$ , es aquel que el sistema clasificador determina como epileptiforme y el experto como no epileptiforme.
- Un resultado falso negativo,  $fn$ , es aquel que el sistema clasificador no puede determinar si es o no epileptiforme y el experto si lo hace.

Los indicadores que más se utilizan en las aplicaciones con EEG son los que se explican a continuación.

- Sensibilidad. Es un valor que mide o expresa la capacidad del clasificador de detectar epilepsia y se calcula como sigue:

---

<sup>55</sup> AARABI, Op. cit., p 2791.

$$\frac{vp}{vp + fn} * 100$$

- Especificidad. Es un valor que mide o expresa la capacidad del clasificador de diferenciar entre cuando hay epilepsia y cuando no. Se calcula como sigue:

$$\frac{vn}{vn + fp} * 100$$

- Selectividad. Es un valor que mide o expresa la capacidad del clasificador de rechazar un falso positivo y se calcula como sigue:

$$\frac{vp}{vp + fp} * 100$$

## 5.4 MARCO LEGAL

Para poder realizar investigaciones en salud, el Ministerio de la Salud mediante la Resolución 8430 de 1993 establece las normas científicas, técnicas y administrativas por las cuales se da cabida a este tipo de investigaciones en Colombia. En este documento se establecen los 3 diferentes tipos de investigaciones, donde la diferencia radica en el riesgo que representa la investigación para los sujetos, también se determina lo imperativo para investigaciones de “riesgo mínimo” y “de riesgo mayor que el mínimo” la elaboración de un consentimiento Informado; documento en donde el sujeto de investigación da la autorización al grupo de investigadores para que en uso total de sus facultades se sirvan de datos en historias clínicas, exámenes médicos o pruebas con tratamientos farmacológicos, haciendo uso confidencial de esta información.

## 2. METODOLOGÍA

### 2.1 TIPO DE ESTUDIO

Es un estudio compuesto de dos fases, la primera es una investigación de riesgo mínimo<sup>56</sup>, en la cual se hace un estudio observacional de tipo descriptivo y corte transversal de adultos y niños del Valle del Cauca. La segunda etapa es observacional de tipo analítico.

### 2.2 POBLACIÓN

Por falta de datos por parte de la Secretaría de Protección Social Municipal, se recurre a los datos que maneja una entidad competente en la problemática como lo es la Fundación Liga Colombiana contra la Epilepsia, capítulo Valle del Cauca Helena Nader de Zaccour. En los registros de enero a junio de 2009 se diagnosticaron 241 personas con Epilepsia por el Médico Neurólogo Guillermo Barrios, es con esta cifra con la que se va trabajar para hacer la distribución y justificar la muestra.

### 2.3 MUESTRA

Teniendo una población,  $N = 241$ , se puede estimar el tamaño de la muestra,  $n$ , por estimación de proporciones<sup>57</sup>, teniendo en cuenta la siguiente expresión para poblaciones infinitas:

$$n = \frac{z^2 pq}{d^2}, \quad (3)$$

donde  $z$  es un valor del número de unidades de desviación estándar para una prueba de dos colas con una zona de rechazo, de igual  $\alpha$ , correspondiente al área de la curva normal estándar con respecto al riesgo fijado  $\alpha/2$ .  $p$  es el factor de muestreo; proporción de la población que se está evaluando.  $q = p - 1$ .  $d$  es el producto entre el coeficiente de confianza,  $\alpha$ , y la desviación estándar  $\sigma$ .

---

<sup>56</sup> Ministerio de la Salud, Resolución 8430 de 1993.

<sup>57</sup> WAYNE W, Op. cit., p. 56

Como la población es finita la expresión anterior se debe modificar de la siguiente forma:

$$n = \frac{Nz^2pq}{d^2(N-1) + z^2pq}, \quad (4)$$

Para este trabajo la proporción de pacientes que se quiere evaluar es 27.5% de la población. Se establece tener una confianza,  $\alpha$ , del 95%. Con este último parámetro se encuentra que  $d$  es 0.05 y por tanto  $z$  es 1.96.

Al reemplazar en la ecuación 4, se tiene entonces que  $n = 92.9 \approx 93$ .

Por tanto se pidió el consentimiento informado a 93 individuos entre pacientes y padres o tutores de los pacientes, para obtener así una copia digital del examen.

## 2.4 RECOLECCIÓN DE INFORMACIÓN

Se generó un formato de Consentimiento informado...véase Anexo A..., de acuerdo a lo establecido en las leyes Colombianas con respecto a estudios en los cuales se haga manejo de pacientes o de información de los mismos como es el caso de este estudio. En el formato se autorizaba al estudiante a pedir una copia digital del examen a la Fundación Liga Colombiana Contra la Epilepsia a cambio de confidencialidad con respecto a la información encontrada en el mismo.

## 2.5 MATERIALES Y MÉTODOS

A continuación se describen los materiales y métodos mediante los cuales fue posible llevar a cabo el proyecto. Como éste lo componen dos fases, se hará la diferenciación de cada una encontrándose sub-secciones para cada fase.

**2.5.1 Materiales de estudio observacional descriptivo.** Para la toma del examen la Fundación Liga Colombiana Contra la Epilepsia, Capítulo Valle contó con:

- Equipo Nicolet/NicoletOne.

- Plataforma software Nicolet vEEG vEEG-Study Room, 5.11.979, Copyright® 2005—VIASYS Healthcare Inc.
- 32 Electroodos de oro.
- Lámpara.
- Camilla Fija.
- Habitación de 2x2 m, con temperatura que oscila entre los 18°C a 21°C.
- 2 Técnicos en Electroencefalografía.
- 1 Médico Neurólogo.

El equipo permite la entrada de 32 canales simultáneos y la visualización de estos en diferentes montajes para el análisis propio del Médico Neurólogo, además maneja una frecuencia de muestreo para todos los canales en todos los registros de 256 Hz.

**2.5.2 Materiales de estudio observacional evaluativo.** Para el desarrollo del sistema se contó con los siguientes implementos y equipos:

- MatLab® R2009a.
- Computadores Personales.
- Edge Diagrammer Versión 6.22.2044, Copyright® 19990-2010 Pacestar Software.
- Nicolet viewer, v5.30.6.1190, Copyright® 2009—VIASYS Healthcare Inc.

**2.5.3 Método De Estudio observacional descriptivo.**

**2.5.3.1 Recolección de información.** Se realizó, durante la 2da semana de septiembre del 2009 hasta la 2da semana de enero del 2010.


El siguiente es el protocolo que siguen en la Fundación Liga Colombiana contra la Epilepsia para realizar el registro de las ondas electroencefalográficas de sus



pacientes y por el cual se rigen también los registros de los pacientes que se tomaron para realizar la base de datos:

- Se procede a explicar al paciente en que consiste el examen mientras se van colocando los electrodos sobre el cuero cabelludo que debe estar seco y limpio. El examen tienen una duración de 10 a 15 minutos aproximadamente. Está compuesto por 2 fases. La primera de vigilia en donde se le pide al paciente que cierre los ojos y los abra solo cuando se le indique, luego se les pone a hiperventilar por 3 minutos máximo. La segunda fase es de foto-estimulación con luz intermitente a diferentes frecuencias. Se le pide que durante el examen debe estar lo más relajado posible y evitar hacer movimientos de los músculos de la cara, el cuello o el cuerpo en general.
- Mediante la colocación de los electrodos según el sistema internacional 10-20 y otros 2 electrodos, neutro y referencia como se muestra en la Figura Tal. se obtienen los registros.

**Figura 13. Localización de electrodos para el registro de EEG en la Fundación Liga Colombiana contra la Epilepsia, capítulo Valle Helena Nader de Zaccour**



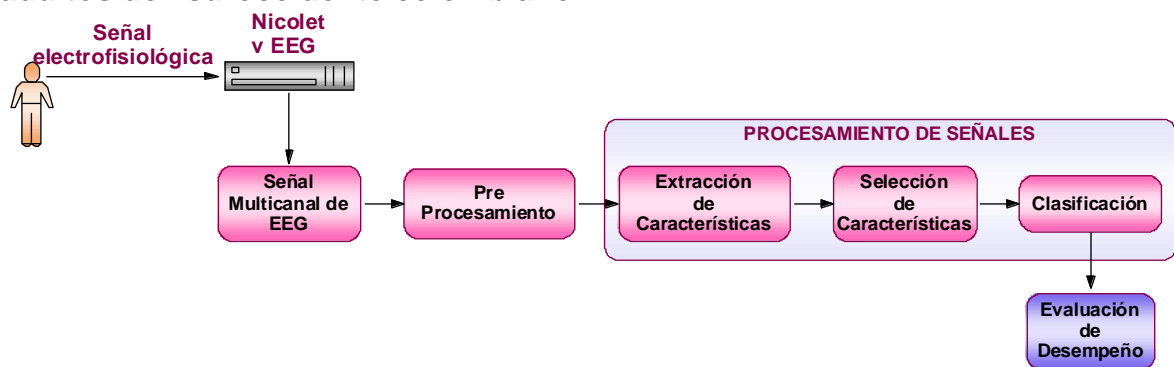
- El examen inicia y la persona debe estar despierta pero con los ojos cerrados, se le pide al paciente de vez en cuando que abra y cierre los ojos y se etiqueta sobre el registro cuando se da cada una de las órdenes, durante esta prueba se espera encontrar en personas sanas ondas alfas simétricas y rítmicas mientras están los ojos cerrados.

- Se detiene la grabación, se le explica o recuerda a la persona como debe respirar para hiperventilar por 3 minutos sin cansarse rápidamente, en algunos pacientes este ejercicio induce descargas y además en todos los pacientes permite que se cansen y puedan conciliar rápidamente el sueño para el segundo estadio de la prueba.. Se comienza a grabar nuevamente.
- Terminados estos 3 minutos se le pide al paciente que descanse y cuando éste por efectos de la hiperventilación comienza a presentar un ritmo más lento y atenuación de la amplitud; estado somnoliento, se procede a hacer fótico o foto estimulación a diferentes frecuencias, esto induce descargas en algunos pacientes. Si el paciente no alcanza a estar somnoliento, durante esta prueba no debe abrir los ojos.

Durante los 2 primeros meses se le pidió de forma aleatoria el consentimiento informado a los pacientes, para las 2 últimos meses fueron seleccionados por recomendación del experto, con lo que se incurre en error de sesgo.

**2.5.4 Método de estudio observacional evaluativo.** A continuación se muestra en la Figura 15 en un diagrama de bloques el método propuesto para el procesamiento de las señales obtenidas por el método descrito anteriormente.

**Figura 14. Sistema de reconocimiento de patrones epileptiformes en EEG de adultos del suroccidente colombiano**



**2.5.4.1 Construcción base de datos.** Una vez terminado el examen se le pidió al paciente o tutor del paciente el consentimiento informado. Se almacenaron para ser empleados en trabajos futuros, pero no se utilizaron los registros que pertenecían a pacientes menores de edad.

Se exportó desde el programa Nicolet en lenguaje ASCII cada uno de los registros en las siguientes opciones:

- Grabación original.
- Montaje Ipsi Ear.
- Montaje Ref CZ.
- Montaje Bipolar.
- Datos sin procesar.

Para la tarea de este proyecto se trabajó con los datos sin procesar ya que son los potenciales por cada canal sin filtros, sin atenuación de la amplitud para mejorar la visualización o cualquier otra modificación de la información. Adicional a esto se llevó un registro escrito y se guardaron algunas imágenes de cada uno de los eventos en aquellos registros que fueron diagnosticados por el experto como anormales por presentar ondas epileptiformes. El archivo que se exporta es de tipo .txt que al importarse a MatLab<sup>®</sup> muestra sus datos en un arreglo de filas y columnas. Teniendo en cuenta la frecuencia de muestreo se pudo relacionar cada dato en ASCII con el suceso en el tiempo así:

Por ejemplo se desea saber a qué fila  $k$ , corresponde un episodio ocurrido después de 5.4 segundos de grabación, sabiendo que la frecuencia de muestreo,  $f$  es 256 Hz, entonces,

$$\frac{5.4}{T_s} + C = k, \quad (6)$$

siendo  $T_s = \frac{1}{256}$  y  $C = 1$ , ya que en MatLab<sup>®</sup> la primera posición del vector será 1; así el tiempo cero (0) es la primera posición del vector.

#### **2.5.4.2 Pre-procesamiento.**


- Filtrado. Digital tipo IIR. De estos filtros se escogió un Butterworth de orden 8, con frecuencias de corte entre los 0.5 Hz y los 30 Hz. A pesar de que tiene una pobre especificidad en frecuencia; esta se compensa escogiendo un orden alto,

esto genera mayores retardos<sup>58</sup>, pero no es significativo a la hora del análisis de la señal EEG.

- **Segmentación.** Se construyeron segmentos haciendo uso de una ventana rectangular, con tamaño de 1280 muestras, correspondientes a 5 segundos de duración en los cuales están contenidas diferentes tipos de señal. Otras investigaciones han segmentado todo el registro porque estos tienen el mismo tamaño, sin embargo como los registros se obtuvieron bajo los parámetros definidos por la Fundación Liga Colombiana contra la Epilepsia, capítulo Valle para la toma de exámenes, estos no tienen la misma duración y por tanto se hace segmentación de las señales de interés, de dos formas; especializada y aleatoria. La especializada, bajo el criterio del médico Neurólogo. De los 20 registros se sacaron 211 segmentos, cada uno como un arreglo de 1280 filas por 21 columnas que son los canales.

En la Figura 17 se muestra la secuencia de pasos. Después de tener todos los segmentos se procede a sacar de cada uno los 3 grupos de características y se ordenan en un arreglo, primero los TD, luego los CW y por último los CC.

**Figura 15. Sistema de segmentación y extracción de características**



<sup>58</sup> MADISETTI, Vijay K. y WILLIAMS. Douglas B. Digital Signal Processing. CRC Press, 1999, 1768 p.

**2.5.4.3 Extracción de características.** Esta etapa fue la más importante de este trabajo. Ya que los clasificadores por si mismos son buenos en el trabajo de clasificación de patrones, sin embargo los resultados son mejores dependiendo del proceso de extracción de características; de cuáles y cuantas se tengan en cuenta.

Como se mencionó en el capítulo anterior, en la literatura existen un número extenso de características a extraer de las señales de EEG. Para este trabajo se escogió extraer los siguientes 4 características de las señales:

- Media.
- Desviación estándar.
- Curtosis.
- Asimetría.

A cada segmento de 1280x21 se le calculó individualmente las medidas estadísticas mencionadas aquí mismo. Esto constituye la extracción de las características en el tiempo. Luego a cada segmento se le aplicó la una DB4 con 3 niveles de descomposición por presentar buenos resultados en la literatura<sup>59</sup>, y a los coeficientes que arrojó la DWT se les extrajo las medidas estadísticas. Lo mismo se hizo para los CC. Por tanto cada patrón tiene 12 características por 21 canales.

El resultado de cada extracción se organizó finalmente en una matriz de 252 filas que son todas las características de los 21 canales, por 211 columnas que es número de patrones.

**2.5.4.4 Selección de características.** Se implementó análisis de componentes principales (PCA) por tener un mejor desempeño con las SVM y con las ANN, según la literatura<sup>60</sup>.

---

<sup>59</sup> ATAEE, Pedram, AVANAKI, Alireza N., SHARIATPANAH Hadi F., KHOEE Seyed M. Ranking features of wavelet-decomposed EEG based on significance in Epileptic seizure prediction. En: 14<sup>th</sup> European Signal Processing Conference(EUSIPO 2008). Septiembre, 2006.

<sup>60</sup> SÖRNMO, Op. cit., p. 284

Como las señales de EEG son multicanal se realizó dos tipos de PCA; uno por características y otro por canales. Esto para determinar en el primero de los casos cuales canales aportan más información que otros y en el segundo caso cual o cuales características están mayormente representadas en un canal.

Para realizar PCA se desarrolló lo siguiente:

- Procesado de la matriz por filas. Donde se realiza mapeo de cada media y desviación estándar de las filas de la matriz de características y se obtiene el factor de transformación.
- Procesado de la matriz por columnas. Donde se aplica el factor de transformación a la matriz de características y esta a su vez arroja sin restricción de tamaño de la nueva matriz, los valores óptimos para la clasificación.
- Evaluación de características. A los diferentes conjuntos de matrices les calcula con un valor de desempeño con diferentes algoritmos.

La literatura trabaja siempre con unas derivaciones y/o canales... véase Tabla 1... con los cuales investigadores han obtenido resultados de exactitud en la clasificación mayores o iguales al 90%<sup>61</sup>.

**Tabla 1. Canales que utiliza la literatura para la tarea de clasificación**

Derivaciones	Canales
F7 – C3 F8 – C4 T5 – O1 T6 – O2	5 6 9 10 11 12 15 16

Se cita aquí porque durante el desarrollo del proyecto se va a tener en cuenta para diversos fines.

**2.5.4.5 Red perceptron multicapa, MLP.** Se hizo la clasificación con 3 diferentes grupos de datos, en el primer grupo se encuentran todas las características, en el segundo grupo que solo están las mejores características y en el tercero la matriz

<sup>61</sup> ALKAN, Ahmet., KOKLUKAYA Etem y SUBASI, Abdulhamit. Automatic seizure detection in EEG using logistic regression and artificial neuronal networks. En: Journal of Neuroscience Methods. Octubre, 2005, vol. 148, p. 167-176.

solo con los canales que propone la literatura. Para esto se hizo los pasos que se detallan a continuación:

- Pre-procesamiento. Normalización de los datos de entrada para valores entre -1 y 1. Se realizó haciendo mapeo de cada fila.
- Partición de los datos. En datos de entrenamiento y datos de validación, de forma aleatoria conservando un 60% de toda la base de datos para datos de entrenamiento y el 40% restante para validación.
- Procesamiento. Implementación de tres redes. La primera con 252 neuronas en la capa de entrada. La segunda con 126 neuronas. La tercera con 96 neuronas. Una sola neurona en la capa de salida con función de activación abierta para en el proceso determinar con cual clasificaba mejor por las características propias de los conjuntos de datos.
- Post-procesamiento. Des-normalización de los datos de entrada, de la misma forma que se hizo la Normalización.

**2.5.4.6 Red de base radial, RBF.** La implementación de esta arquitectura de red a diferencia de las Perceptrón Multicapa es más sencilla, puesto que estas redes son muy robustas. Los parámetros de entrada son:

- Error Objetivo.
- Dispersión.
- Número de Neuronas de Entrada.
- Número de Neuronas entre Displays.

Se trabajo con los conjuntos de datos de entrenamiento y validación de la partición realizada para las MLP y por supuesto se hizo también con los 3 grupos diferentes de características.

**2.5.4.7 Máquinas con vectores de soporte, SVM.** Se clasificó con los 2 grupos diferentes de características. Y se probó con kernel como:

- Lineal.
- Base Radial.
- Polinomial.
- Cuadrático.

Luego se hizo optimización suave del margen por medio de BoxConstrain.

**2.5.4.8 Evaluación de desempeño.** Se realizó por medio de las siguientes herramientas, ya definidas en el capítulo anterior.

- Error de clasificación.
- Curvas de error.
- Matriz de confusión.



### 3. RESULTADOS

#### 3.1 ESTUDIO OBSERVACIONAL DESCRIPTIVO

De los consentimientos informados resultaron 94 registros distribuidos como se muestra en la Tabla 1.

**Tabla 2. Registros obtenidos**

<b>Pacientes/Diagnóstico</b>	<b>NORMAL</b>	<b>ANORMAL</b>
NIÑOS	29	19
ADULTOS	27	19
	56	38
Total	94	

De los que presentaron un electroencefalograma anormal se agruparon en 3 categorías como se muestra en la Tabla 2.

**Tabla 3. Clases de registros**

<b>Pacientes/Anormalidad</b>	<b>Paroxístico</b>	<b>Tipo Epileptiforme</b>	<b>Otra Patología</b>
NIÑOS	5	9	5
ADULTOS	8	10	1
	13	19	6
Total	38		


Nota: Se define a niño como toda persona menor de 18 años según la constitución colombiana de 1991.

De los datos recolectados para la construcción de la base de datos, sólo se trabajó con aquellos que correspondían a los registros de pacientes adultos; ya que la detección de epilepsia en niños es una tarea más compleja por el comportamiento de las neuronas que se encuentran en continuo entrenamiento y aprendizaje. En Anexo B se presentan los datos de edad y sexo correspondientes.

## 3.2 ESTUDIO OBSERVACIONAL EVALUATIVO

El sistema de reconocimiento de patrones que se obtuvo al seguir la metodología propuesta en el ítem inmediatamente anterior se modificó conforme al desarrollo del trabajo y se muestra el diagrama final en la Figura 18.

**Figura 16. Diagrama real del sistema**



**3.2.1 Construcción de base de datos.** Se tomaron 20 registros, 10 de ellos de las personas diagnosticados por el experto como pacientes que presentan patrones epileptiformes y otros 10 se escogieron entre los que fueron diagnosticadas por el experto como pacientes con EEG normales. La Tabla 4 muestra de forma organizada la información referente a la clase de cada registro. Donde 1 significa que presenta epilepsia y 0 que no presenta epilepsia.

**Tabla 4. Registros de la base de datos**

Registro	t inicial	t final	Clase
p1	11:48:00	11:59:19	1
p2	11:55:01	12:09:43	1
p3	11:56:24	12:12:40	1
p4	2:36:12	2:47:19	1
p5	3:26:04	3:37:13	1
p6	10:14:47	10:30:05	1
p7	3:26:11	3:37:12	1
p8	11:41:46	11:58:29	1
p9	12:03:21	12:16:27	1
p10	11:48:00	11:59:19	1
n11	4:53:01	5:07:19	0
n12	2:40:31	2:53:33	0
n13	10:53:41	11:09:34	0
n14	2:09:27	2:21:36	0


n15	2:36:10	2:49:41	0
n16	2:47:28	3:03:16	0
n17	3:10:48	3:24:22	0
n18	2:03:46	2:16:17	0
n19	4:09:46	4:23:03	0
n20	11:01:23	11:13:38	0

**3.2.2 Pre-procesamiento.** La segmentación de los 20 registros dio como resultado un total de 92 segmentos de patrones epileptiformes correspondientes a 8 registros de los pacientes que presentan ondas epileptiformes, 19 segmentos de otros patrones y de pacientes normales se tomaron aleatoriamente 10 segmentos de cada uno, para un total de 211 segmentos que componen la base de datos.

### 3.2.3. Procesamiento.

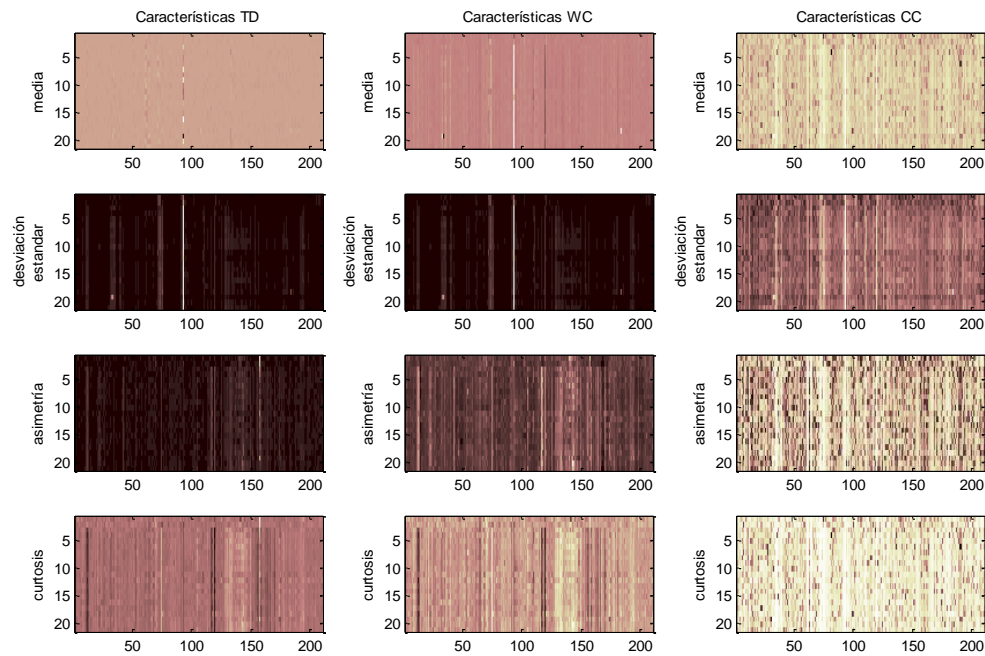
**3.2.3.1 Extracción de características.** Con las 12 características extraídas se conformó la matriz de características que se muestra en la Figura 19. La matriz es de 252x211, donde las filas corresponden a las 12 características por cada uno de los 21 canales y 211 columnas que son los patrones.

**Figura 17. Imagen de la matriz de características**



A simple vista, al observar la matriz de características, se podía esperar que algunas de estas no aportaran a la tarea de clasificación significativamente, ya que tenían valores muy próximos entre sí, o cercanos a cero. Como se muestra en la Figura 20, donde se cambio la forma de visualización para seguir evaluando cualitativamente la representación de las características, es necesario hacer la evaluación cuantitativa con PCA, lo que se hizo en el ítem siguiente.

**Figura 18. Matrices de imágenes por cada característica**



**3.2.3.2 Selección de características.** Los dos tipos de PCA; uno por características y otro por canales se implementaron y se obtuvo del procesamiento de la matriz por filas un factor de tolerancia igual a 0.001. Del procesamiento de la matriz por columnas lo que se muestra en las Tablas 6 y 7, que se hizo sin alguna restricción de tamaño. Y finalmente de la evaluación de las características que se hizo mediante el algoritmo de vecinos cercanos, Nearest Neighbor<sup>62</sup>, también se presentan en las mismas Tablas.

En la Tabla 5, se encuentra la codificación utilizada para describir los resultados de PCA.

<sup>62</sup> DUIN, R.P.W., JUSZCZAK, P., PACLIK, P., PEKALSKA, E., De RIDDER, D., TAX, D.M.J. y VERZAKOV, S. PRTTools4.1, A Matlab Toolbox for Pattern Recognition, Delft University of Technology, 2007.

**Tabla 5. Codificación de las características**

<b>Características</b>	<b>Numeración</b>
<b>TD</b>	
Media	1
Desviación Estándar	2
Asimetría	3
Curtosis	4
<b>WC</b>	
Media	5
Desviación Estándar	6
Asimetría	7
Curtosis	8
<b>CC</b>	
Media	9
Desviación Estándar	10
Asimetría	11
Curtosis	12

- **PCA por canales.** Se obtuvo 21 matrices, una por cada canal con dimensiones de 12x211. Se aplicó PCA para seleccionar de cada canal las características que más aportan información y se evaluó por medio del algoritmo ya mencionado. En la Tabla 6 se encuentran relacionados estos datos y los resultados de la evaluación que nos indica para cada caso que tanta información se aporta y entre más cercano sea este valor a uno, el aporte es mayor.

**Tabla 6. PCA por Canales**

<b>Canal</b>	<b>Características</b>	<b>Cantidad de información C = 1-error</b>
1	3 4 6 7 8 12	0,621
2	6 7 8 10 12	0,54
3	2 6 7 8 10 12	0,55
4	2 4 6 7 8 10 11 12	0,493
5	3 5 7 8 10 12	0,569
6	2 7 8 10	0,498
7	7 10 12	0,55
8	2 3 6 8 10 12	0,526
9	6 8 10 11 12	0,469
10	3 4 5 6 8 12	0,526

11	2 6 7 8 9 10	0,493
12	10 12	0,574
13	2 3 7 8 9 10 12	0,555
14	6 7 10 11 12	0,507
15	3 8 10 12	0,545
16	4 7 8 11 12	0,535
17	3 5 8 12	0,54
18	2 7 8 9 10 12	0,559
19	2 4 6 8 9	0,469
20	7 10 11	0,512
21	3 4 6 8 10 12	0,507

Como se puede ver, el canal 4 es el que aporta un mayor número de características con un valor de desempeño del 49.3%. Mientras que el canal 1 con las características TD de curtosis y asimetría, de WC la desviación estándar, curtosis, asimetría y de CC con asimetría es el que mayor información aporta pues presenta un valor de 62.1% en la evaluación.

La característica menos determinante es la media y la más determinante es la asimetría de los coeficientes cepstrales, CC, ya que el 95.2% de los canales lo presentan.

- **PCA por características.** Se obtuvo 12 matrices una por cada característica, con dimensiones de 21x211. Se aplicó PCA para seleccionar en cuales canales la característica tenía una mayor representación y se evaluó por medio del algoritmo ya mencionado. En la Tabla 7 se encuentran descritos y las medidas de la evaluación correspondiente.

**Tabla 7. PCA por Características**

Característica	Canales	Cantidad de información C = 1-error
1	4 9 10 13 14 20 21	0,701
2	1 4 9 10 11 15 16 19 21	0,559
3	2 3 4 11 14 15 18 19 20	0,54
4	12 14 15 16 17 18 21	0,512
5	3,5,6,7,8,9,11,13,16,17,18,19,20	0,512
6	4 7 8 9 10 11 15 19 21	0,592

7	10 12 14 15 16 19 20 21	0,469
8	1 4 11 12 14 20 21	0,559
9	13 16 17 18 19	0,626
10	1,3,8,9,10,11,14,15,16,17,18,19,21	0,517
11	1 2 13 14 15 16 17 18 19 20	0,512
12	2 6 8 9 14 20 21	0,545

La media en el dominio del tiempo es la característica que está mayormente representada por 7 canales al obtener un desempeño del 70%. La desviación estándar de los CC, es la característica que está representada por un mayor número de canales; con más de la mitad de todos los canales, y tiene un representación del 51.7%.


**3.2.4 Clasificación.** Se hizo la clasificación por medio de 3 clasificadores, cada uno en dos procesos. El primero con la matriz que contiene todas las características, llamada **mc**. Mientras que el segundo se hizo con la matriz de las mejores características, llamada **mbc**. Aunque se hizo reiteradas veces la clasificación a continuación sólo se mostrara aquellos resultados que obtuvieron un mejor desempeño en la clasificación.

**3.2.4.1 Red perceptron multicapa, MLP.** Para el primer proceso, es decir clasificación con la matriz de datos mc, la red que mejores resultados mostró, se implementó con los parámetros mostrados en la Tabla 8 y los valores del error cuadrático medio, MSE, se muestran en la misma tabla. El resultado de la salida del clasificador se muestra en la Figura 21.

**Tabla 8. Detalles clasificador MLP para mc**

Parámetros de entrada	
Función de entrenamiento de la red	Gradiente descendente
Función de activación de neuronas de c.o	Tangente sigmoideal
Función de activación en la neurona de c.s	Lineal
Número de c.o	2
Número de neuronas en c.o	[25 25]
Salida	
MSE de entrenamiento	0.128
MSE de validación	0.1964

**Figura 19. Clasificación de la MLP con mc**




Para el segundo proceso, es decir clasificación con la matriz de datos mbc, la red que mejores resultados mostró, se implementó con los parámetros mostrados en la Tabla 9. El resultado de la salida del clasificador se muestra en la Figura 22.

**Tabla 9. Detalles clasificador MLP para mbc**

Parámetros de entrada	
Función de entrenamiento de la red	Gradiente Descendente
Función de activación de neuronas de c.o	Tangente sigmoideal
Función de activación en la neurona de c.s	Lineal
Número de c.o	2
Número de neuronas en c.o	[50 25]
Salida	
MSE entrenamiento	0.2379
MSE validación	0.2381



**Figura 20. Clasificación de la MLP con mbc**




**3.2.4.2 Red base radial, RBF.** Para la clasificación con mc, la red que mejores resultados mostró, se implementó con los parámetros consignados en la Tabla 10. El resultado de la salida del clasificador se muestra en la Figura 23.

**Tabla 10. Detalles clasificador RBF para mc**

Parámetros de entrada	
Error objetivo	0
Dispersión	5
Número de neuronas en c.e	80
Número de neuronas entre displays	25
Salida	
MSE de entrenamiento	0.057042
MSE de validación	0.2202

**Figura 21. Clasificación de la RBF con mc**




Para la clasificación con mbc, la red que mejores resultados mostró, se implementó con los parámetros mostrados en la Tabla 11. El resultado de la salida del clasificador se muestra en la Figura 24.

**Tabla 11. Detalles clasificador RBF para mbc**

Parámetros de entrada	
Error objetivo	0
Dispersión	6
Número de neuronas en c.e	5
Número de neuronas entre displays	25
Salida	
MSE de entrenamiento	0.24684
MSE de validación	0.2024

**Figura 22. Clasificación de la RBF con mbc**



**3.2.4.3 Máquinas con vectores de soporte.** Para ambos procesos se clasifico con los 4 kernel y posteriormente se hizo suave optimización del margen utilizando restricciones de caja, *the Box Constraint*. Se buscó diferentes factores de suavizado y el que mejores resultados obtuvo para la primera clasificación fue  $1e-6$  y para la segunda clasificación fue  $5e-6$ . Los resultados para la primera clasificación se encuentran consignados en la Tabla 12.


**Tabla 12. Detalles clasificador SVM para mc**

Kernel	MSE entrenamiento	MSE validación	BoxCons $1e-6$	
			MSE entrenamiento	MSE validación
Lineal	0	0.2857	0.3314	0.3333
Polinomial	0.0355	0.4048	0.0414	0.3810
RBF	0	0.3810	0	0.3810
Cuadrático	0	0.3810	0.3095	0.3095


Con los anteriores resultados se puede señalar al kernel lineal como el que le provee a la SVM un menor error de validación, sin embargo cuando se realiza un suavizado del margen, el error se incrementa. Contrario a lo que ocurre con el kernel cuadrático, que primero tiene un error de validación alto y con el suavizado, como es de esperarse disminuye. En la figura 25 podemos observar la salida de la SVM cuando usa el kernel cuadrático y en la Figura 26 como mejora la

respuesta del clasificador con el factor mencionado anteriormente para el suavizado

**Figura 23. Clasificación de la SVM con mc de entrada y kernel cuadrático**



**Figura 24. Mejora en la clasificación de la SVM**




Algo similar pasa para el segundo proceso; clasificación con mbc. Como se va a observar en la Tabla 13 el kernel lineal es el de menor error en la validación, pero el kernel cuadrático es el único que mejora con el suavizado. En las figuras 27 y

28 se encuentran las salidas del clasificador para este kernel, sin el suavizado y después del suavizado respectivamente.


**Tabla 13. Detalles clasificador SVM para mbc**

Kernel	MSE entrenamiento	MSE validación	BoxCons 5e-5	
			MSE entrenamiento	MSE validación
Lineal	0.0888	0.3333	0.3432	0.3571
Polinomial	0	0.3333	0	0.3095
RBF	0	0.3810	0	0.3810
Cuadrático	0	0.4048	0.2012	0.2381

**Figura 25. Clasificación de la SVM con mbc**




**Figura 26. Mejora en la clasificación de la SVM**



**3.2.5 Evaluación de desempeño.** A continuación se encuentran las tablas y gráficas donde están consignados los datos complementarios referente a esta etapa, ya que durante todo este capítulo se han presentado otros indicadores.


**3.2.5.1 Curvas de error para MLP.** El proceso de clasificación con cada una de las matrices tiene unas curvas asociadas para mostrar como fue el entrenamiento y la validación de los datos de entrada. En la Figura 27 se encuentra la respuesta del clasificador a los datos de entrada mc en el entrenamiento y la validación. En donde se observa como la cantidad de falsos positivos es mayor cuando realiza el entrenamiento que la validación

**Figura 27. ROC de MLP para entrenamiento y validación de mc**




Para la clasificación de mbc ocurre un fenómeno parecido, en la figura 28 se puede observar como estas curvas con respecto a las de mc, mejoran el entrenamiento y la validación, no es una mejora contundente, pero si marca la diferencia con respecto a la clasificación anterior, lo que podría indicar que este clasificado con la matriz de mejores características puede detectar mejor cuando se presenta epilepsia.

**Figura 28. ROC de la MLP para entrenamiento y validación de mbc**




### 3.2.5.2 Curvas de error para RBF.

**Figura 29. ROC de la RBF para entrenamiento y validación de mc**



En la figura anterior se muestra el desempeño de la RBF cuando tiene los datos de la matriz mc, se puede observar como la cantidad de falsos positivos es mayor cuando realiza la validación que el entrenamiento. Y además el entrenamiento es el mejor hasta el momento ya que se acerca mucho al ideal que es un escalón unitario.

**Figura 30. ROC de la RBF para entrenamiento y validación de mbc**






La figura anterior muestra el desempeño del la RBF cuando tiene los datos de la matriz mbc, es hasta el momento el mejor desempeño en cuanto a validación, ya que la cantidad de falsos positivos es mucho menor que cualquiera de los otros procesos realizados con la misma arquitectura o diferente.

Comparativamente las RBF's con las ANN's son mejores clasificando, tal y como se esperaba según la literatura. A este nivel se puede señalar a las RBF para este trabajo con una base de datos diferente a la que usa la literatura como un mejor clasificador de las redes neuronales.

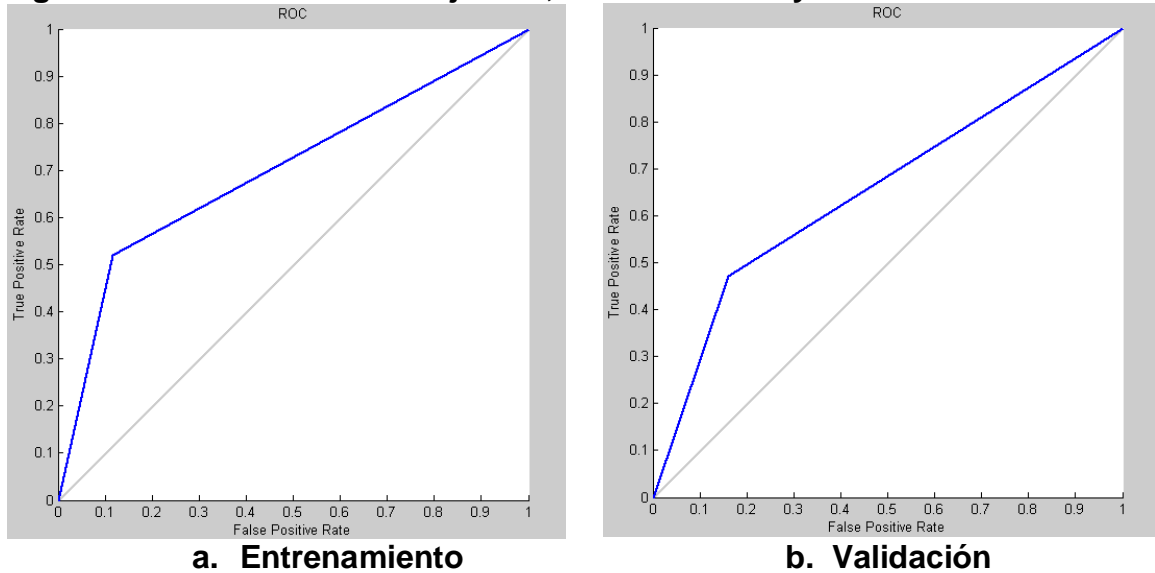
**3.2.4.3 Curvas de error para SVM.** Como ya se había mencionado ...en la sección Tal ... para la clasificación se utilizaron diferentes kernel, pero el que mejor desempeño mostró fue el cuadrático y las curvas que se encuentran a continuación en las Figuras 31, 32, 33 y 34 corresponden al clasificador con este kernel.

**Figura 31. ROC de la SVM para entrenamiento y validación de mc**



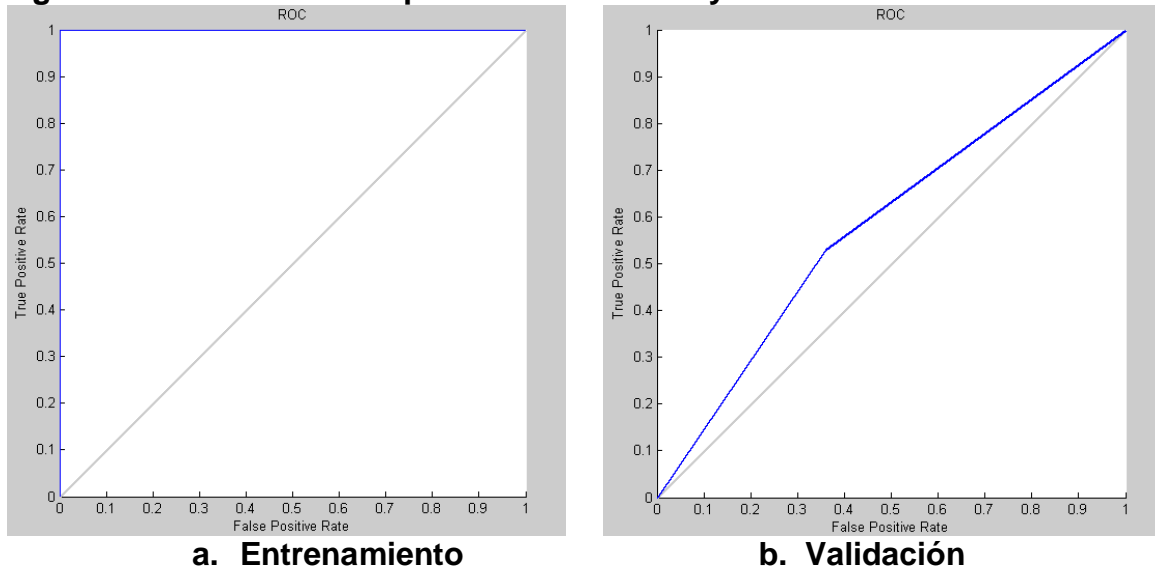
En la figura anterior podemos observar un entrenamiento perfecto para un kernel cuadrático que no asegura, como se puede observar, que la validación tenga que ser buena por que se haya echo un buen entrenamiento. En la Figura 32 se aprecia como la validación mejora significativamente con respecto a la actual, cuando se hace la optimización suavizada del margen.

**Figura 32. ROC de la SVM mejorada, entrenamiento y validación de mc**



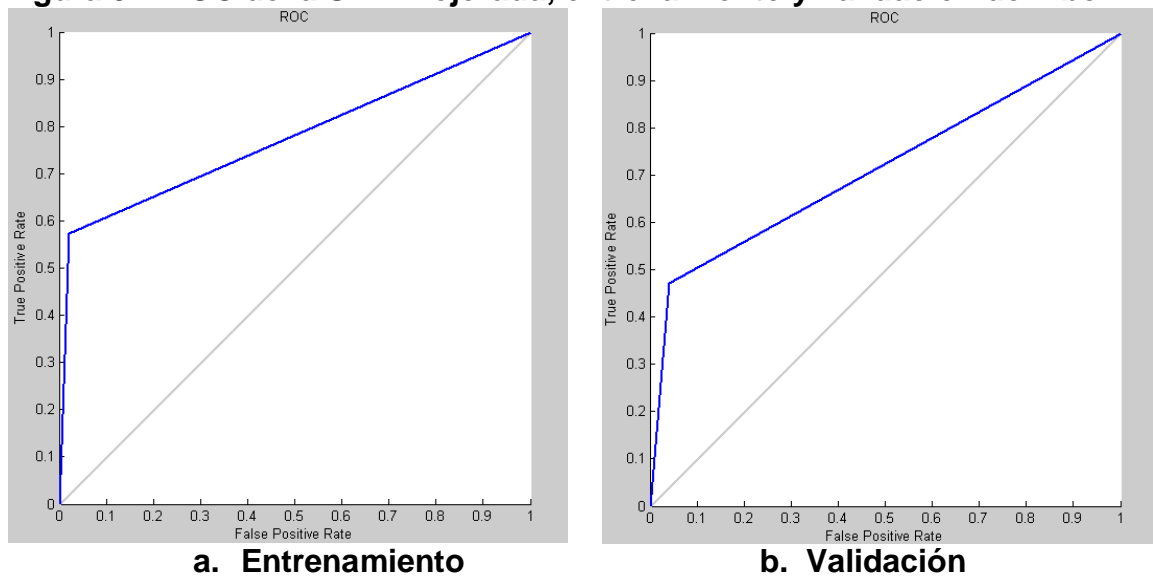
En las figuras 33 y 34 se observan las curvas de clasificación con los datos mbc, en los cuales como en el caso anterior, primero se observa un aprendizaje perfecto y una pobre validación, la peor de todos los clasificadores.

**Figura 33. ROC de la SVM para entrenamiento y validación de mbc**



Pero con la optimización del margen de la Figura 34 el panorama cambia totalmente y se tiene aunque aceptables, los resultados que menos falsos positivos presenta.

**Figura 34. ROC de la SVM mejorada, entrenamiento y validación de mbc**



En conclusión se demuestra que un excelente entrenamiento no asegura una buena clasificación.

Que las SVM's aseguran el menor número de falsos positivos en la tarea de reconocimiento de patrones que cualquier otro clasificador.

**3.2.4.4 Matrices de confusión de MLP.** A continuación se pasa a analizar de forma cuantitativa el desempeño de los clasificadores.

Los resultados de la matriz de confusión para la MLP con mc como datos de entrada... véase Figura 33... muestran para la matriz de validación en su diagonal principal que de 17 patrones epileptiformes clasifica 14, es decir un 33,3% de todos los datos. Y de los 25 patrones sanos clasifica 17, lo que equivale a un 40,5% de todos los datos. En conclusión la MLP tiene una precisión en la clasificación de un 73,8%.

**Figura 35. Matriz de confusión de la MLP, entrenamiento y validación de mc**

		valores objetivo				
		1	2			
salida clasificador	1	36 21,3%	19 11,2%	65,5%	34,5%	
	2	39 23,1%	75 44,4%	65,8%	34,2%	
		48,0% 52,0%	79,8% 20,2%	65,7% 34,3%		
<b>a. Entrenamiento</b>						
		valores objetivo				
		1	2			
salida clasificador	1	14 33,3%	8 19,0%	63,6%	36,4%	
	2	3 7,1%	17 40,5%	85,0%	15,0%	
		82,4% 17,6%	68,0% 32,0%	73,8% 26,2%		
<b>b. Validación</b>						

Los resultados de la matriz de confusión para la MLP con los datos mbc, muestran para la matriz de validación en su diagonal principal que de 17 patrones epileptiformes clasifica 12, equivalentes a un 28.6% de todos los datos y de los 25 patrones sanos clasifica 19, lo que equivale a un 45.2% de todos los datos. En conclusión tiene una precisión en la clasificación de un 73.8%.

**Figura 36. Matriz de confusión de la MLP para entrenamiento y validación de mbc**

		valores objetivo				
		1	2			
salida clasificador	1	44 26,0%	28 16,6%	61,1%	38,9%	
	2	31 18,3%	66 39,1%	68,0%	32,0%	
		58,7% 41,3%	70,2% 29,8%	65,1% 34,9%		
<b>a. Entrenamiento</b>						
		valores objetivo				
		1	2			
salida clasificador	1	12 28,6%	6 14,3%	66,7%	33,3%	
	2	5 11,9%	19 45,2%	79,2%	20,8%	
		70,6% 29,4%	76,0% 24,0%	73,8% 26,2%		
<b>b. Validación</b>						

Comparando los resultados se puede resaltar a la MLP con datos mc de entrada, como mejor clasificador de la clase de epilepsia con un 82,4% de tasa de aciertos, mientras que la de mejores características, mbc, tiene un mejor desempeño clasificando la segunda clase, de patrones normales con un 76%

### 3.2.4.5 Matrices de confusión de RBF.

Los resultados de la matriz de confusión para la RBF con los datos mc como entrada... véase Figura 35... muestran en la diagonal principal de la matriz de validación, que de los 17 patrones epileptiformes clasifica 13, equivalentes a un 31% de todos los datos y de los 25 patrones sanos clasifica 18, lo que equivale a un 42.9% de todos los datos. En conclusión tiene una precisión en la clasificación de un 73.8%, el mismo que MLP para la matriz de mejores características.

**Figura 37. Matriz de confusión de la RBF para entrenamiento y validación de mc**

		valores objetivo				
		1	2			
salida clasificador	1	68 40,2%	1 0,6%	98,6%		
	2	7 4,1%	93 55,0%	93,9%		
		90,7% 9,3%	98,9% 1,1%	95,3% 4,7%		
		valores objetivo				
		1	2			
salida clasificador	1	13 31,0%	7 16,7%	65,0%		
	2	4 9,5%	18 42,9%	81,8%		
		76,5% 23,5%	72,0% 28,0%	73,8% 26,2%		

**a. Entrenamiento**

**b. Validación**

Los resultados de la matriz de confusión para la RBF con los datos mbc... véase Figura 36... muestran en la diagonal principal de la matriz de validación, que de 17 patrones epileptiformes clasifica 11, equivalente un 26,2% de todos los datos y de los 25 patrones sanos clasifica 22, lo que equivale a un 80%. En conclusión tiene una precisión en la clasificación de un 78.6%.

**Figura 38. Matriz de confusión de la RBF para entrenamiento y validación de mbc**

		valores objetivo		
		1	2	
salida clasificador	1	40 23,7%	15 8,9%	72,7% 27,3%
	2	35 20,7%	79 46,7%	69,3% 30,7%
		53,3% 46,7%	84,0% 16,0%	70,4% 29,6%
a. Entrenamiento				

		valores objetivo		
		1	2	
salida clasificador	1	11 26,2%	3 7,1%	78,6% 21,4%
	2	6 14,3%	22 52,4%	78,6% 21,4%
		64,7% 35,3%	80,0% 12,0%	78,6% 21,4%
b. Validación				

Comparando los resultados se puede resaltar a la RBF con datos mc como datos de entrada, como mejor clasificando la clase de epilepsia con un 76.5% de tasa de aciertos, mientras que la de mejores características tiene un mejor desempeño clasificando la segunda clase, de patrones normales con un 80%. Adicionalmente se puede decir que las RBF son mejores clasificando en general, ya que con la matriz de mbc obtiene un 78,6% de precisión.

Con lo anterior se puede decir que aunque las curvas muestran que las RBF son mejores evitando los falsos positivos por se puede inferir que podrían ser mejores clasificando que las MLP. Hasta aquí la MLP tiene un mayor porcentaje de aciertos con la clase que contiene epilepsia, para cualquiera de los procesos, lo que indica que aunque se sabe que mbc tiene la información más representativa de la mc, se pierden ciertas características que le aportan generalidad a la tarea de clasificación.

**3.2.4.6 Matrices de confusión para SVM.** Acompañando las matrices de confusión, en esta sección se encuentra una tabla donde se relacionan los datos de las tasas de clasificación correcta para cada kernel y cómo esta varía con la optimización del margen. En la Tabla 14 se encuentra lo anterior para una SVM con mc como datos de entrada. Aquí se observa como se había descrito en secciones anteriores como el kernel cuadrático es que mejor desempeño presenta, es por esta razón que las matrices de confusión que se presentan sólo corresponden a la SVM con este kernel...véase Figura 37 y 38...

**Tabla 14. Tasas de clasificación de SVM con mc**

Kernel	Correcto entrenamiento	Correcta clasificación	BoxCons 1e-6	
			Correcto entrenamiento	Correcta Clasificación
Lineal	100%	71.4%	66.9%	66.7%
Polinomial	96.4%	59.5%	95.9%	61.9%
RBF	100%	61.9%	100%	61.9%
Cuadrático	100%	61.9%	72.2%	69.0%

**Figura 39. Matriz de confusión de la SVM para entrenamiento y validación de mc**

		valores objetivo		
		1	2	
salida clasificador	1	75 44,4%	0 0,0%	100% 0,0%
	2	0 0,0%	94 55,6%	100% 0,0%
		100% 0,0%	100% 0,0%	100% 0,0%
<b>a. Entrenamiento</b>				
		valores objetivo		
		1	2	
salida clasificador	1	11 26,2%	10 23,8%	52,4% 47,6%
	2	6 14,3%	15 35,7%	71,4% 28,6%
		64,7% 35,3%	60,0% 40,0%	61,9% 38,1%
<b>b. Validación</b>				

Observando la matriz de validación, la clasificación de la clase de Epilepsia es quien presenta una mayor tasa de aciertos.

**Figura 40. Matriz de confusión de la SVM mejorada, entrenamiento y validación de mc**

		valores objetivo		
		1	2	
salida clasificador	1	39 23,1%	11 6,5%	78,0% 22,0%
	2	36 21,3%	83 49,1%	69,7% 30,3%
		52,0% 48,0%	88,3% 11,7%	72,2% 27,8%
<b>a. Entrenamiento</b>				
		valores objetivo		
		1	2	
salida clasificador	1	8 19,0%	4 9,5%	66,7% 33,3%
	2	9 21,4%	21 50,0%	70,0% 30,0%
		47,1% 52,9%	84,0% 16,0%	69,0% 31,0%
<b>b. Validación</b>				

En la Tabla 15 se encuentra los datos de los diferentes kernel para la SVM con mbc como datos de entrada. Aquí se observa lo mismo que en el primer proceso, un mejor desempeño con el kernel cuadrático. En las figuras 39 y 40 se muestran las matrices de confusión correspondientes al proceso antes y después de la optimización respectivamente.

Kernel	Correcto entrenamiento	Correcta clasificación	BoxCons 5e-5	
			Correcto entrenamiento	Correcta Clasificación
Lineal	91.1%	66.7%	65.7%	64.3%
Polinomial	100%	66.7%	100%	69.0%
RBF	100%	61.9%	100%	61.9%
Cuadrático	100%	59.5%	79.9%	76.2%

		valores objetivo		
		1	2	
salida clasificador	1	75 44,4%	0 0,0%	100% 0,0%
	2	0 0,0%	94 55,6%	100% 0,0%
		100% 0,0%	100% 0,0%	100% 0,0%

**a. Entrenamiento**

		valores objetivo		
		1	2	
salida clasificador	1	9 21,4%	9 21,4%	50,0% 50,0%
	2	8 19,0%	16 38,1%	66,7% 33,3%
		52,9% 47,1%	64,0% 36,0%	59,5% 40,5%

**b. Validación**

80



**Figura 42. Matriz de confusión de la SVM mejorada para entrenamiento y validación de mbc**

		valores objetivo		
		1	2	
salida clasificador	1	43 25,4%	2 1,2%	95,6% 4,4%
	2	32 18,9%	92 54,4%	74,2% 25,8%
		57,3% 42,7%	97,9% 2,1%	79,9% 20,1%

**a. Entrenamiento**

		valores objetivo		
		1	2	
salida clasificador	1	8 19,0%	1 2,4%	88,9% 11,1%
	2	9 21,4%	24 57,1%	72,7% 27,3%
		47,1% 52,9%	96,0% 4,0%	76,2% 23,8%

**b. Validación**

Tras el mejoramiento nuevamente la clase de no epilepsia es quien muestra una mayor tasa de aciertos con un 96%. El más alto para esta clase, en todo el desarrollo de este trabajo.

Los resultados para la SVM presentan una mayor precisión en la detección de Epilepsia cuando se utiliza la matriz con todas las características, mc. La optimización suave del borde definitivamente mejora esta tasa y sólo con kernel cuadrático.

Con los resultados del mejoramiento se puede decir que la mejora que le otorga el boxconstrain a la SVM, consiste en mejorar la clasificación de todo el sistema sin diferenciar entre clases.

Con los resultados mostrados hasta el momento podría pensarse que tiene mejores desempeños las ANN's en la tarea y guiándose sólo por los resultados numéricos de las tablas se estaría en un acierto, sin embargo se debe tener en cuenta que el kernel cuadrático se escogió porque comienza con un mal desempeño y tras la optimización mejora por encima de los otros y eso es lo que se espera finalmente que con una optimización de margen la máquina adquiera mayor capacidad de decisión.

#### 4. CONCLUSIONES

La detección de epilepsia por medio de máquinas de aprendizaje fue un trabajo demandante por el tiempo que tomó la primera parte del proyecto; la recolección de la información para hacer la base de datos y la construcción de la misma y exigente, por el procesamiento de estas señales utilizando todos los canales, contrario a lo que hacen otros investigadores, ya que se proyectaba de forma ambiciosa obtener resultados muy parecidos a los de la literatura, sin embargo para la realizadora valió la pena, ya que al trabajar con una base de particular datos local, se permite dimensionar una alternativa de solución a una problemática de la comunidad y real al trabajar con todos los canales como lo hace un experto.

El trabajo cumplió con todos los objetivos propuestos en el anteproyecto. La metodología que se planteó para la realización del mismo, condujo de forma fluida el proceso para la consecución del objetivo principal del proyecto.

En cuanto a los resultados que se obtuvo, teniendo como precedente los que arroja la literatura, se determina que los de este trabajo son aceptables. No son mejores porque la representación de las características extraídas, no estaba lo suficientemente diferenciada en el espacio de características.

Vale la pena aclarar aclarar que la literatura trabajó con otras bases de datos lo que significa que los métodos que ellos implementen tienen resultados coherentes para si mismos. Ya que mientras no existan ampliamente documentados y validados métodos de unificación, los trabajos no pueden compararse de forma

Durante el desarrollo del proyecto se mencionó una matriz con la que la literatura trabajaba, esta se tuvo en cuenta a la hora de internamente nutrir los conceptos, comparar y hacer juicios, sin embargo colocar los resultados aquí mismo no tendría relevancia en este estudio ya que estos fueron obtenidos bajo otros parámetros como la base de datos, la población de estudio de la misma, la cantidad de participantes, el número de registros, etc. Por tanto los resultados que los otros investigadores obtuvieron, solo nutren la metodología, pero ponerlos le restaría rigurosidad a este trabajo.

Es determinante para trabajos futuros extraer características diferentes a las empleadas en este trabajo, ya que estas a excepción de los coeficientes cepstrales no son lo suficientemente significativas en la tarea de reconocimiento de patrones, por los resultados aceptables que se obtuvo. Se recomienda intentar

con energía promedio durante el ataque, pendiente de caída, periodograma, coeficientes de reflexión etc.

Se debe dejar claro que los valores que se obtuvo de error de clasificación se les dio la relevancia que merecen, pero estos indicadores no son determinantes a la hora decir si el clasificador es mejor en la tarea o mejor que otro, ya que en muchas ocasiones los clasificadores al medirles el desempeño tenía un valor de clasificación muy bajo y al mismo tiempo la tasa de clasificación era buena.

A diferencia de la literatura las SVM trabajaron mejor con un kernel cuadrático en vez de gaussiano

Tal como se esperaba de los clasificadores de ANN's el que mejor desempeño obtuvo fue el de base radial. De igual manera se esperaba que la SVM tuviese un mejor desempeño que la base radial, sin embargo para este trabajo no fue así. Y las ANN's siguieron presentando mayores tasas de clasificación correcta.

Finalmente el trabajo deja abiertas varias posibilidades para continuar investigando; como realizar combinación de clasificadores para determinar si de esta forma se presenta un mayor desempeño en la tarea.

## BIBLIOGRAFÍA

AARABI, Ardalan., WALLOIS, Fabrice., y GREBE, Reinhard. A multistage knowledge-based system for EEG seizure detection in newborn infants. En: Clinical Neurophysiology. Agosto, 2008, vol. 118, p 2781-2797.

-----,-----,----- . Automated neonatal seizure detection: A multi-state classification systems through feature selection based on relevance and redundancy analysis. En: Clinical Neurophysiology. Diciembre, 2005, vol. 117, p. 328-340.

ATAEE, Pedram, AVANAKI, Alireza N., SHARIATPANAH Hadi F., KHOEE Seyed M. Ranking features of wavelet-decomposed EEG based on significance in Epileptic seizure prediction. En: 14<sup>th</sup> European Signal Processing Conference(EUSIPO 2008). Septiembre, 2006.

ALKAN, Ahmet., KOKLUKAYA Etem y SUBASI, Abdulhamit. Automatic seizure detection in EEG using logistic regression and artificial neuronal networks. En: Journal of Neuroscience Methods. Octubre, 2005, vol. 148, p. 167-176.

BEGG, Rezaul., LAI, Daniel T.H. y PALANISWAMI, Marimuthu. Computational Intelligence in Biomedical Engineering. Boca Raton: Taylor & Francis Group, 2008. 375 p.

BETANCOURT, Gustavo A. Las Máquinas de Soporte Vectorial, (SVMs). En: Scientia et Technica. Abril, 2005, vol. 10, no. 27, p. 67-72.

BLUM, Andrew S. y RUTKOVE, Seward B. The Clinical Neurophysiology Primer. New Jersey: Humana Press Inc, 2007. 526 p.

BRONZINO, Joseph D. Biomedical Engineering Handbook. 2 ed. Boca-Raton: CRC Press LLC, 2000. 3187 p.

CHANDAKA, Suryannarayana., CHATTERJEE, Amitava y MUNSHI, Sugata. Cross-correlation aided support vector machine Classifier for classification of EEG signals. En: Experts systems with applications. 2009, vol. 36, p. 1329-1336.

COLOMBIA. MINISTERIO DE SALUD. Resolución 8430 de 1993 (Octubre 4). Por el cual se establecen las normas científicas, técnicas y administrativas para la investigación en salud. Bogotá D.C.: Ministerio de Salud, 1993.

CRISTIANINI, Nello., SHAW-TAYLOR, Jhon. An introduction to Support Vector Machines: an other kernel-based learning methods. Cambridge: Cambridge University Press, 2000. 189 p.

DUIN, R.P.W., JUSZCZAK, P., PACLIK, P., PEKALSKA, E., De RIDDER, D., TAX, D.M.J. y VERZAKOV, S. PRTools4.1, A Matlab Toolbox for Pattern Recognition, Delft University of Technology, 2007.

DURKA, Piotr. Matching pursuit and unification in EEG analysis. Norwood: Artech House Inc. 2007, 184 p.

GUYTON, Arthur C., HALL, John E. Tratado de Fisiología Médica. 10 ed. México: McGraw-Hill, 2001. 1280 p.

GÜZELİŞ, Cüneyt y ACIR, Nurettin. Automatic spike detection in EEG by a two-stage procedur based on support vector machines. En: Computers in Biology and Medicine. Agosto, 2004, vol. 34, p. 561-575.

INSTITUTO COLOMBIANO DE NORMAS TÉCNICAS y CERTIFICACIÓN. Trabajos escritos: presentaciones y referencias bibliográficas. NTC 1486, 5613, 4490. Bogotá D.C.: ICONTEC, 2008. 92 p.

KANDEL, Eric R., SCHWARTZ, James H., JESSELL, Thomas M. Principles of Neural Science. 4 ed. United State of America: McGraw-Hill, 2000. 1416 p.

KEMAL K. M., SUBASI, Abdulhamit y RIZA O, H. Neural Network with Periodogram and Autoregressive Spectral Analysis methods in detection of Epileptic Seizure. En: Journal of Medical Systems. Diciembre, 2004, vol. 28, no.6, p. 511-522.

LOPEZ SOTELO, Jesús A. y CAICEDO BRAVO, Eduardo F. Una aproximación práctica a las redes neuronales. Cali: Universidad del Valle, 2009. 217 p.

MADISETTI, Vijay K. y WILLIAMS. Douglas B. Digital Signal Processing Handbook II. Atlanta: CRC Press, 1999, 1768 p.

MARQUES DE SÁ, Joaquin. Applied statistics: Using SPSS, STATISTICA, MATLAB and R. Portugal: Springer, 2007. 505 p.

----- . Pattern Recognition: Concepts methods and applications. Portugal: Springer, 2001, 317 p.

MEYER-BÄSE, Anke. Pattern Recognition for Medical Imaging. San Diego: Elsevier Inc, 2004. 385 p.

OCAK, Hasan. Automatic detection of epileptic seizures in EEG using discrete wavelet transform and approximate entropy. En: Experts Systems with Applications. Enero, 2008, vol. 36, no.1, p. 2027-2036.

OROZCO ALZATE, Mauricio. Selección efectiva de características wavelet en la identificación de bioseñales 1-D y 2-D usando algoritmos genéticos. Trabajo de grado Ingeniero Electrónico. Manizales: Universidad Nacional de Colombia. Facultad de Ingeniería y Arquitectura. Departamento de Ingeniería Eléctrica, Electrónica y Computación, 2005. 80 p.

PATNAIK, L.M. y MANYAM, Ohil K. Epileptic EEG detection using neural networks and post-classification. En: Computer Methods and Programs in Biomedicine. Agosto, 2008, vol. 91, p. 100-109.

SANEI, Saeid. y CHAMBERS, J.A. EEG Signal Processing. West Sussex: John Wiley and Sons, Ltd, 2007. 289 p.

SCHÖLKOPF, Bernhard. y SMOLA, Alexander J. Learning with kernels: Support Vector Machines, Regularization, Optimization and Beyond. United States of America: The MIT Press, 2002, 626 p.

SÖRNMO, Leif. y LAGUNA, Pablo. Bioelectrical signal processing in cardiac and neurological applications. Academic Press, Elsevier, 2005. 688 p.

SRINIVASAN, V., ESWARAN, C. y SRIRAAM, N. Artificial Neural Network based epileptic detection using time-domain and frequency-domain features. En: Journal of Medical Systems Diciembre, 2005, vol. 29, no.6, p. 647-660.

TATUM, William O. Handbook of EEG interpretation. United States of America: Demos Medical Publishing, 2008. 275 p.

TEJEIRO MARTÍNEZ, Jose. EEG Normal. Barcelona: Viguera Editores, 2010[consultada el día 10 de julio]. Disponible en internet: [www.viguera.com/pdf/muestra/8485424557.pdf](http://www.viguera.com/pdf/muestra/8485424557.pdf)

ÜBEYLİ, Elif D. Least square Support Vector Machine employing model-based methods coefficients for analysis of EEG signals. En: Experts Systems with applications. Enero, 2010, vol. 37, p. 233-239.

WAYNE W, Daniel. Biostatistics: A foundation for Analysis in the Health Sciences. 7 ed. United Georgia: JOHN WILEY & SONS, INC, 1999. 183 p.

WORLD HEALTH ORGANIZATION, INTERNATIONAL LEAGUE AGAINST EPILEPSY, INTERNATIONAL BUREAU FOR EPILEPSY, Atlas: Epilepsy care in the world. Thönex: WHO Library Cataloguing, 2005. 93 p.

## ANEXOS

### Anexo A. Consentimiento Informado

<p align="center"><b>FORMULARIO DE CONSENTIMIENTO INFORMADO</b></p> <p><b>TÍTULO:</b> Detección de Epilepsia en señales electroencefalográficas mediante el uso de Redes Neuronales Artificiales y Máquinas con vectores de soporte, primera fase: Construcción de Base de Datos.</p> <p><b>PROTOCOLO No.:</b></p> <p><b>INVESTIGADOR:</b> Andrea Ceballos Herrera</p> <p><b>DIRECCIÓN:</b> Departamento de Automática y Electrónica. Universidad Autónoma de Occidente.</p> <p align="center"><b>INTRODUCCIÓN</b></p> <p>En este consentimiento, el término "Ud." hace referencia a "Ud. /su niño/niña".</p> <p>El médico que asesora esta investigación ha determinado que Ud. reúne los requisitos principales para participar en la primera fase de este estudio.</p> <p>El investigador o asesor médico explicará los procedimientos y contestará cualquier pregunta que tenga acerca de este Formulario de Consentimiento Informado y / o del estudio. Por favor, lea detenidamente este documento y no dude en consultar al investigador o asesor médico sobre cualquier pregunta que tenga acerca del estudio y/o la información provista a continuación.</p> <p align="center"><b>OBJETIVO DEL ESTUDIO</b></p> <p>Como Ud. Consulta a la Fundación Liga Colombiana contra la epilepsia, Capítulo Valle del Cauca en Cali, Colombia, se lo ha invitado a participar en este estudio de investigación. Debido a que hoy en día para el 30% de la población que padece de Epilepsia no existe tratamientos medicamentosos o quirúrgicos que sean efectivos, por tanto se requieren de estudios en nuestro medio inicialmente que determinen automatizadamente si existen patrones epileptiformes en señales de electroencefalografía o no, para pensar en realizar un dispositivo que permita el control de la epilepsia.</p> <p>En este estudio se recolectarán señales electroencefalográficas de pacientes que presenten Epilepsia y personas que no la presenten.</p> <p align="center"><b>DESCRIPCIÓN DEL ESTUDIO Y PROCEDIMIENTOS</b></p> <p>Este es un estudio observacional descriptivo de corte transversal en niños y adultos que consultan a la Fundación Liga Colombiana contra la Epilepsia, Capítulo Valle del Cauca en Cali, Colombia en donde se determinará con herramientas computacionales de inteligencia artificial si padecen o no Epilepsia.</p> <p>En este estudio participarán aproximadamente 90 personas en total. Luego de haber sido asignado a participar en el estudio, los registros de electroencefalografía que Ud. se realizó en la Fundación Liga Colombiana contra la Epilepsia serán utilizados para el entrenamiento de algoritmos que aprenderán los patrones de las señales y podrán después determinar si en cualquier señal electroencefalográfica se está presentando Epilepsia.</p> <p align="center"><b>RIESGOS Y MOLESTIAS</b></p> <p>La participación en este estudio por la recolección de las señales electroencefalográficas no implica riesgos ni molestias.</p> <p align="center"><b>ALTERNATIVAS</b></p> <p>No es obligatorio que Ud. participe en este estudio para recolección de señales electroencefalográficas.</p> <p align="center"><b>POSIBLES BENEFICIOS PARA LOS PARTICIPANTES</b></p> <p>El participar en la investigación no trae beneficios inmediatos para quien lo hace. Sin embargo, a largo plazo muy posiblemente se beneficien ellos, sus familiares y muchas otras personas en las mismas condiciones que Ud., ya que investigaciones como esta, se encuentran encaminadas a resolver necesidades de la comunidad y se espera poder llegar a tener un prototipo implantable que realice el control oportuno de las crisis Epileptiformes, además es primordial tanto para el investigador como para el personal de la Fundación Liga Colombiana contra la Epilepsia mejorar la calidad de vida de Ud. y los suyos.</p> <p align="center"><b>COSTOS</b></p> <p>La participación en este estudio no tiene ningún costo adicional para el paciente ni para sus padres.</p> <p align="center"><b>CONFIDENCIALIDAD</b></p> <p>Los registros de su participación en este estudio se mantendrán confidenciales en la medida permitida por las leyes locales, estatales y federales. El médico del estudio y/o de la Fundación Liga Colombiana contra la Epilepsia, Capítulo Valle del Cauca en Cali, Colombia, representantes del patrocinador, Universidad Autónoma de Occidente, las autoridades regulatorias y los Comités de Ética/Docencia e Investigación,</p>
---



podrán inspeccionar y tendrán acceso a los datos confidenciales que lo identifican a Ud. por su nombre. Los Comités de Ética/Docencia e Investigación son comités que evalúan los estudios para garantizar que se protejan los derechos y el bienestar de los participantes y que el estudio se lleve a cabo éticamente. Dada la necesidad de entregar información a estos organismos, no puede garantizarse una absoluta confidencialidad. Ud. no será identificado en ninguna publicación de los datos. Al firmar este formulario de consentimiento, Ud. autoriza al médico asesor del estudio a revelar sus registros médicos relacionados con el estudio a las personas e instituciones arriba mencionados.

#### A QUIÉN DIRIGIR LAS PREGUNTAS RELATIVAS A ESTE ESTUDIO

Ud. tiene el derecho de hacer preguntas con respecto a este estudio en cualquier momento y le pedimos que lo haga. El médico asesor del estudio será informado acerca de toda nueva información relativa a su seguridad. Si tiene alguna pregunta relativa a este estudio o si presenta un daño o enfermedad relacionado con la investigación, contacte a la Srta. Andrea Ceballos Herrera al teléfono 3241 537.

Si tiene preguntas con respecto a sus derechos como sujeto de una investigación, Ud. podrá contactar al Comité de Docencia e Investigación de la Universidad Autónoma de Occidente al teléfono 3188000.

#### PARTICIPACIÓN VOLUNTARIA Y DERECHO DE NEGARSE O RETIRARSE

Su participación en este estudio es voluntaria. Ud. podrá negarse a participar o podrá discontinuar su participación en cualquier momento durante el estudio, sin penalidad ni pérdida de beneficios.

#### DESCONTINUACIÓN DE SU PARTICIPACIÓN

Su participación en el estudio podrá ser discontinuada por el estudiante investigador, el médico asesor del estudio, el patrocinador, u otro organismo gubernamental sin su consentimiento si Ud. deja de reunir los criterios para continuar en el estudio.

#### DECLARACIÓN DE CONSENTIMIENTO INFORMADO

Yo, \_\_\_\_\_, identificado con la cédula No. \_\_\_\_\_ de \_\_\_\_\_, (padre / madre / tutor de) \_\_\_\_\_

(nombre del niño) he comprendido toda la información que se me suministró acerca de la participación de mi niño/a en este estudio. He tenido la oportunidad de comentar dicha información y hacer preguntas. Todas ellas han sido respondidas a mi satisfacción. Acepto de plena voluntad que mi niño/a participe en este estudio. Recibiré una copia firmada de esta declaración de consentimiento informado.

La decisión de aceptar que mi niño/a participe en este estudio de investigación no anula ninguno de sus derechos en el caso de negligencia u otra responsabilidad legal de las personas involucradas en este estudio. Autorizo a que se revelen los registros médicos de mi niño/a al patrocinador (incluso sus contratistas o representantes) y otros organismos gubernamentales, y el Comité de Ética e Investigación.

Firma del padre/madre/tutor

Fecha/hora de firma

Nombre del padre/madre/tutor (en imprenta)

Relación con el paciente

Nombre del paciente (en imprenta)

Firma de la persona que obtiene el consentimiento

Fecha/hora de firma

Nombre de la persona que obtiene el consentimiento (en imprenta)

Firma del Primer Testigo

Fecha/hora de firma

Nombre del Primer Testigo (en imprenta)

Firma del Segundo Testigo

Fecha/hora de firma

Nombre del Segundo Testigo (en imprenta)

## Anexo B. Edad y Sexo de los registros para construcción de base de datos

Registro	edad	Sexo
p1	20	F
p2	50	M
p3	25	M
p4	38	M
p5	20	F
p6	42	F
p7	30	F
p8	23	M
p9	47	M
p10	28	M
n11	22	F
n12	47	F
n13	62	F
n14	23	M
n15	57	M
n16	40	M
n17	78	F
n18	79	F
n19	66	M
n20	22	M

## Anexo C. Segmentos

Los siguientes son los segmentos y la codificación que se usó en la construcción de la base de datos.

Registro p1				Registro p4			
Segmento	t inicial	t final	Codificación	Segmento	t inicial	t final	Codificación
aa1	11:49:42	11:49:46	O.L	aa9	2:36:22	2:36:26	p.O
aa2	11:50:19	11:50:23	O.L	aa10	2:37:30	2:37:34	p.O
aa3	11:50:40	11:50:44	O.L	aa11	2:39:45	2:39:49	p.O
aa84	11:51:30	11:51:34	O.L	aa12	2:40:33	2:40:37	p.O
aa85	11:50:47	11:50:51	O.L	aa13	2:39:29	2:39:33	p.O
aa86	11:51:17	11:51:21	O.L	ab11	2:37:39	2:37:43	V y C.K
aa87	11:58:30	11:58:34	O.L	ab12	2:35:12	2:35:16	A.mus
aa88	11:52:51	11:52:55	O.L				
aa89	11:48:44	11:48:48	O.L				
aa90	11:52:34	11:52:38	O.L				
aa91	11:58:53	11:58:57	O.L				
aa92	11:59:05	11:59:09	O.L				
ab1	11:53:51	11:53:55	A.mov				
ab2	11:56:51	11:56:55	A.mov				
ab3	11:57:48	11:57:52	A.mov				

Registro p2				Registro p5			
Segmento	t inicial	t final	Codificación	Segmento	t inicial	t final	Codificación
aa4	12:01:16	12:01:20	Pp.O	aa14	3:26:12	3:26:16	O.A
aa5	12:05:08	12:05:12	O.A	aa15	3:28:01	3:28:04	p
aa6	12:06:55	12:06:59	p.O	aa16	3:27:32	3:27:36	O.A
aa7	12:07:27	12:07:31	p.O y Pp.O	aa17	3:28:27	3:28:31	O.A
ab4	12:07:53	12:07:57	A.mus	aa18	3:28:51	3:28:55	O.A
ab5	12:07:37	12:07:41	R	aa19	3:29:02	3:29:06	O.A
ab6	12:06:35	12:06:39	Somn	aa20	3:29:09	3:29:13	O.L
ab7	12:06:18	12:06:22	E.S	aa21	3:29:55	3:29:59	O.A
ab8	12:02:50	12:02:54	A.R	aa22	3:30:07	3:30:11	O.A
				aa23	3:29:41	3:29:45	O.L
				aa24	3:29:20	3:29:24	O.A
				aa25	3:30:15	3:30:19	O.A
				aa26	3:30:22	3:30:26	O.A
				aa27	3:30:37	3:30:41	O.A
				aa28	3:30:55	3:30:59	O.A
				aa29	3:31:42	3:31:46	O.A
				aa30	3:32:11	3:32:15	O.A
				aa31	3:33:03	3:33:07	O.A
				ab13	3:27:31	3:27:35	O.lmn
				ab14	3:30:26	3:30:30	C.K
				ab15	3:33:11	3:33:15	V

Registro p3			
Segmento	t inicial	t final	Codificación
aa8	12:11:05	12:11:09	O.A
ab9	11:57:40	11:57:44	A.mov
ab10	12:00:28	12:00:32	A.mov

Registro p6				Registro p7			
Segmento	t inicial	t final	Codificación	Segmento	t inicial	t final	Codificación
aa32	10:17:36	10:17:40	O.A	aa55	3:26:55	3:26:59	O.A
aa33	10:18:00	10:18:04	O.A	aa56	3:30:08	3:30:12	O.A
aa34	10:18:39	10:18:43	O.L	aa57	3:30:12	3:30:16	O.A
aa35	10:18:52	10:18:56	O.A	aa58	3:30:21	3:30:25	O.A
aa36	10:19:30	10:19:34	O.A	aa59	3:30:39	3:30:43	O.A
aa37	10:19:11	10:19:15	O.A y O.L	aa60	3:31:06	3:31:10	O.A
aa38	10:29:00	10:29:04	O.A	aa61	3:31:10	3:31:14	O.A
aa39	10:29:59	10:30:03	O.A	aa62	3:31:15	3:31:19	O.A
aa40	10:29:35	10:29:39	O.A	aa63	3:31:30	3:31:34	O.A
aa41	10:29:44	10:29:48	O.A	aa64	3:31:41	3:31:45	O.A
aa42	10:22:07	10:22:11	O.L	aa65	3:32:54	3:32:58	O.A
aa43	10:22:02	10:22:06	O.L	aa66	3:32:12	3:32:16	O.A
aa44	10:22:19	10:22:23	O.L	aa67	3:33:57	3:34:01	O.A
aa45	10:24:09	10:24:13	O.L	aa68	3:34:42	3:34:46	O.A
aa46	10:24:25	10:24:29	O.L	aa69	3:34:48	3:34:52	O.A
aa47	10:27:43	10:27:47	O.L	aa70	3:35:57	3:36:01	O.A
aa48	10:28:23	10:28:27	O.L	aa71	3:37:07	3:37:11	O.A
aa49	10:27:51	10:27:55	O.L	ab18	3:33:21	3:33:25	A.A2
aa50	10:28:08	10:28:12	O.L	Registro n11			
aa51	10:28:48	10:28:52	O.A	Segmento	t inicial	t final	Codificación
aa52	10:28:32	10:28:36	O.A	ac1	4:56:06	4:56:10	hiper
aa53	10:28:35	10:28:39	O.A	ac2	4:53:08	4:53:12	alfa
aa54	10:28:54	10:28:58	O.A	ac3	4:59:18	4:59:22	A.mov
ab16	10:16:20	10:16:24	A.o	ac4	5:00:24	5:00:28	alfa
ab17	10:26:12	10:26:16	Hs	ac5	5:01:02	5:01:06	A.mov
				ac6	5:03:01	5:03:05	A.mov+45Hz
				ac7	5:03:30	5:03:34	Somn
				ac8	5:04:15	5:04:19	Somn
				ac9	5:04:31	5:04:35	Somn
				ac10	5:06:07	5:06:11	Somn
				Registro n12			
				Segmento	t inicial	t final	Codificación
				ac11	2:40:41	2:40:45	parpadeo
				ac12	2:41:02	2:41:06	ojos abiertos
				ac13	2:48:35	2:48:39	Paa+F15Hz
				ac14	2:49:10	2:49:14	F25Hz
				ac15	2:50:44	2:50:48	Somn
				ac16	2:52:42	2:52:46	Somn
				ac17	2:51:21	2:51:24	Somn
				ac18	2:50:09	2:50:13	Paa+F45Hz
				ac19	2:52:49	2:52:53	Somn
				ac20	2:50:01	2:50:04	Paa+F45Hz
Registro p9							
Segmento	t inicial	t final	Codificación				
aa72	12:03:54	12:03:58	Pp				
aa73	12:05:13	12:05:17	Pp				
aa74	12:05:37	12:05:41	Pp				
aa75	12:11:48	12:11:52	Pp				
aa76	12:12:09	12:12:13	Pp				
aa77	12:12:25	12:12:29	Pp				
aa78	12:13:09	12:13:13	Pp				
aa79	12:15:11	12:15:15	Pp				
aa80	12:15:45	12:15:49	Pp				
aa81	12:16:17	12:16:21	Pp				
aa82	12:12:59	12:13:03	O.L				
aa83	12:07:06	12:07:10	O.L				
ab19	12:04:26	12:04:30	parpadeo				



Registro n13				Registro n16			
Segmento	t inicial	t final	Codificación	Segmento	t inicial	t final	Codificación
ac21	10:54:16	10:54:20	alfa	ac51	2:47:31	2:47:35	alfa
ac22	10:54:38	10:54:42	ojos abiertos	ac52	2:47:50	2:47:54	alfa
ac23	10:56:00	10:56:04	alfa	ac53	2:48:18	2:48:22	ojos abiertos
ac24	10:56:30	10:56:34	A.mov	ac54	2:48:38	2:48:42	alfa
ac25	10:57:50	10:57:54	alfa	ac55	2:49:16	2:49:20	alfa
ac26	10:59:22	10:59:26	E.S	ac56	2:50:40	2:49:44	alfa
ac27	11:00:35	11:00:39	A.mov	ac57	2:51:14	2:51:18	alfa
ac28	11:00:57	11:01:01	A.mus	ac58	2:51:52	2:51:56	alfa
ac29	11:01:35	11:01:39	alfa+posth	ac59	2:55:31	2:55:35	alfa+hiper
ac30	11:02:07	11:02:11	A.mov	ac60	2:59:49	2:59:53	Somn+F20Hz

Registro n14				Registro n17			
Segmento	t inicial	t final	Codificación	Segmento	t inicial	t final	Codificación
ac31	2:09:30	2:09:34	alfa	ac61	3:10:55	3:10:59	alfa
ac32	2:09:46	2:09:50	A.o+A.mov	ac62	3:11:02	3:11:06	A.mov
ac33	2:10:13	2:10:17	A.mov	ac63	3:11:21	3:11:25	alfa
ac34	2:10:38	2:10:42	alfa	ac64	3:11:51	3:11:55	alfa
ac35	2:11:03	2:11:07	alfa	ac65	3:12:09	3:12:13	ojos abiertos
ac36	2:16:25	2:16:29	A.mov	ac66	3:12:28	3:12:32	alfa
ac37	2:20:27	2:20:31	A.mov+15Hz	ac67	3:17:10	3:17:14	A.mov
ac38	2:10:52	2:10:56	beta	ac68	3:19:12	3:19:16	E.S
ac39	2:11:42	2:11:46	alfa	ac69	3:12:47	3:12:51	alfa
ac40	2:12:32	2:12:36	A.mov	ac70	3:23:35	3:23:39	alfa

Registro n15				Registro n18			
Segmento	t inicial	t final	Codificación	Segmento	t inicial	t final	Codificación
ac41	2:36:11	2:36:15	alfa	ac71	2:03:56	2:04:00	alfa
ac42	2:36:35	2:36:39	alfa	ac72	2:04:18	2:04:22	alfa
ac43	2:36:58	2:37:02	parpadeo	ac73	2:05:00	2:05:04	ojos abiertos
ac44	2:37:45	2:37:49	alfa	ac74	2:08:09	2:08:13	hiper
ac45	2:38:13	2:38:17	alfa	ac75	2:11:12	2:11:16	alfa+F20Hz
ac46	2:40:35	2:40:39	hiper	ac76	2:14:32	2:14:36	alfa
ac47	2:42:59	2:43:03	alfa+hiper	ac77	2:15:28	2:15:32	alfa
ac48	2:44:23	2:44:27	alfa	ac78	2:16:34	2:16:38	alfa
ac49	2:44:37	2:44:41	5Hz	ac79	2:14:21	2:14:25	alfa
ac50	2:46:14	2:46:18	Somn+40Hz	ac80	2:13:45	2:13:49	A.mov

Registro n19				Registro n20			
Segmento	t inicial	t final	Codificación	Segmento	t inicial	t final	Codificación
ac81	4:10:03	4:10:07	alfa	ac91	11:01:38	11:01:42	rit.lento/alfa
ac82	4:10:12	4:10:16	ojos abiertos	ac92	11:02:01	11:02:05	rit.lento/alfa
ac83	4:20:45	4:20:49	Somn	ac93	11:02:37	11:02:41	A.mov
ac84	4:21:52	4:21:56	Somn	ac94	11:07:07	11:07:11	hiper+A.mov
ac85	4:22:12	4:22:16	Somn	ac95	11:09:33	11:09:37	A.mov
ac86	4:11:14	4:11:18	A.mov	ac96	11:10:00	11:10:04	A.mov
ac87	4:17:28	4:17:32	alfa+A.mus	ac97	11:10:07	11:10:11	A.mov
ac88	4:11:14	4:11:18	parpadeo	ac98	11:11:09	11:11:13	A.mov
ac89	4:16:09	4:16:13	F15Hz+Somn	ac99	11:12:09	11:12:13	A.mov
ac90	4:18:22	4:18:26	alfa	ac100	11:12:35	11:12:39	A.mov

El registro número 20 corresponde a un paciente que presenta hemiparesia del lado derecho. Por eso presenta para un mismo segmento dos clases de onda en algunos segmentos, puesto que su hemisferio izquierdo trabaja mas lento que el derecho por la de-sincronía motora que padece.


Los siguientes es la codificación usada para la comprensión de la información

Símbolo	Descripción
A.mov	Artefacto movimiento
A.mus	Actividad muscular
R	Ronquidos
Somn	Somnoliento
E.S	Electrodo suelto
A.R	Artefacto de red
V	Vertex
C.K	Complejos K
O.lmn	Ondas Imagógicas
Hs	Husos de sueño
A.o	Apertura de ojos
C.o	Cierre de ojos
AA2	Artefacto del referencial
hiper	Hiperventilación
F( )Hz	Fótico de 5 Hz-45 Hz
Paa	Período atenuación amplitud
posth	Post Hiperventilación

Símbolo	Descripción
O.L	Onda Lenta o Theta
O.A	Onda Aguda
Pp.O	Polipunta-onda
p.O	punta-onda
Pp	Polipunta


Anexo D. Formas de Onda de Vigilia

Onda alfa



Anexo E. Formas de Ondas de sueño


Complejos K



## Vertez



## Husos de sueño





## Anexo F. Formas de Onda patológicas

### Ondas agudas




### Punta Onda Aguda



## Punta Onda Lenta



## Poli-punta Onda




## APÉNDICE A. ANATOMÍA Y FISIOLOGÍA DEL CEREBRO

### NEUROANATOMÍA

**El cráneo.** O calota craneal es una estructura de hueso compacto y delgado, conformada por 22 huesos; 8 de los cuales sirven de bóveda para el cerebro, ya que se encajan entre si para proteger el cerebro estos son: uno occipital, uno frontal, 2 temporales, 2 parietales, el esfenoides y el etmoides. Los 14 restantes conforman los huesos de la cara como lo muestra la figura siguiente.

**Figura 1. Huesos del Cráneo**




**Fuente:** [http://www.sidisalta.com.ar/Cuerpo/pages/CRANEO\\_O.htm](http://www.sidisalta.com.ar/Cuerpo/pages/CRANEO_O.htm). 15 de marzo de 2009.

**El cerebro.** Es el órgano más complejo e importante del cuerpo humano. Es quien controla todas las actividades y permite que interactuemos con nuestro entorno sin que la condición de estar totalmente aislado -por si solo no ve, no escucha, no huele, no siente-, le impida hacerlo satisfactoriamente. Este es parte fundamental del sistema nervioso central; que esta conformado también por el cerebelo, la médula espinal y el tallo cerebral. Es por eso que si este sistema falla no podemos captar el mundo como es y no podemos desenvolvernos en el mismo como queremos.

Se compone de 2 hemisferios; izquierdo y derecho, quienes se encargan de las funciones contra laterales del cuerpo, estos a su vez se forman por lóbulos como muestra la Figura 2; el occipital, parietal, temporal y frontal, sus nombres vienen del hueso que los protege. Esta organización centralizada y descentralizada a la vez, permite que si alguna porción del cerebro no funciona como debería, no se afecten o comprometan las demás funciones vitales del cuerpo. En contraste con el cerebro de otras especies como los insectos que tienen cerca de sus órganos vitales un comando central que regula su función, así por ejemplo en una cucaracha que tiene 8 órganos vitales encontramos 8 cerebros repartidos por todo el cuerpo. El cerebro humano por supuesto es una versión muchísimo más evolucionada; podríamos decir que es la unión de todos estos cerebros en un solo lugar, que actúan de forma conjunta e individual al mismo tiempo.

**Figura 2. Lóbulos del cerebro**




**Fuente:** KANDEL, Eric R., SCHWARTZ, James H., JESSELL, Thomas M. Principles of Neural Science. 4 ed. United State of America: McGraw-Hill, 2000. p. 324.

## NEUROFISIOLOGÍA

**Las Neuronas.** Son células especializadas que conforman el sistema nervioso central. Su tarea principal es la comunicación entre si por medio de la sinapsis. Un fenómeno químico y eléctrico que ocurre cuando el axón de una neurona...véase Figura 3... se posiciona en la vecindad de una dendrita de una segunda neurona y por medio de un neurotransmisor viaja podría decirse que el impulso eléctrico de la primera neurona hasta la segunda.

**Figura 3. Neurona biológica**




**Fuente:** [www.correodelmaestro.com](http://www.correodelmaestro.com). 15 de marzo de 2009.

Conformadas como lo muestra la figura por un núcleo, las dendritas pegadas a este, un axón tan largo como se requiera compuesto de mielina, nodos de ranvier células gliares y células de Schwann.

**La sinapsis.** Como ya se había mencionado es un fenómeno químico y eléctrico. Tanto sobre el axón como en la dendrita existen canales que son activados por afinidad con el neurotransmisor que causa la reacción.

#### Figura 4. Sinapsis



**Fuente:** KANDEL, Eric R., SCHWARTZ, James H., JESSELL, Thomas M. Principles of Neural Science. 4 ed. United State of America: McGraw-Hill, 2000. p. 183.

## APÉNDICE B. EPILEPSIA

La epilepsia se puede clasificar de 2 formas, según su causa: primaria y secundaria. Y según el lugar o la forma en la que se originan dentro del cerebro, focal, pequeño mal y gran mal.

### Clasificación según causa.

- **Primaria o idiopática.** No tiene causa aparente, puede presentarse por predisposición genética; alteraciones de la membrana de la Neurona: el nivel basal de excitabilidad del sistema nervioso se eleva por encima de un umbral crítico<sup>63</sup>. También puede desencadenarse por consumir drogas, ingerir alcohol o falta de sueño.
- **Secundaria o Sintomática.** Daño cerebral previo es la causante de las crisis.

### Clasificación según origen.

- **Focal o psicomotora.** Es la epilepsia que se genera en uno o varios lugares y afecta las funciones relacionadas al lugar en donde se originan. Por lo general esta no se puede detectar sino con un registro de EEG, esta puede observarse cuando se presentan los comúnmente llamados ticks: en un ojo, ceja, por lo general un músculo en particular o también se manifiesta en acciones repetitivas de las cuales la persona puede estar conciente de su ejecución o no; como abotonarse o desabotonarse una camisa<sup>64</sup> y no tiene ningún control sobre esto.

### Figura 6. Epilepsia Psicomotora



**Fuente:** GUYTON, Arthur C., HALL, John E. Tratado de Fisiología Médica. 10 ed. México: Mc-Graw Hill, 2001. 836 p.

<sup>63</sup> GUYTON, Arthur C., HALL, John E. Tratado de Fisiología Médica. 10 ed. México: Mc-Graw Hill, 2001. 839 p.

<sup>64</sup> Epilepsia [Videograbación]. Madrid: Sociedad Española de Neurología, 2006. Video en formato Flash: sonido, color.



**Pequeño Mal.** Puede generarse como una epilepsia focal; que contagia a otras neuronas y se expande por la corteza cerebral levemente a la vez que va haciéndose mas notoria su padecimiento. Sin embargo una focal no siempre desencadena en una de pequeño Mal<sup>65</sup>. En esta se puede observar movimientos bruscos de los cuales la persona es conciente pero no tiene control alguno sobre estos.

**Figura 7. Epilepsia Pequeño Mal**



**Fuente:** GUYTON, Arthur C., HALL, John E. Tratado de Fisiología Médica. 10 ed. México: Mc-Graw Hill, 2001. 836 p.

**Gran Mal.** Es la mas grave de todas, se puede generar en zonas profundas del cerebro, extendiéndose desde el interior hacia todas las direcciones del cerebro y sobre toda la corteza, lo que genera normalmente que la persona se estremezca totalmente de manera muy brusca, ya que una de las zonas mas afectadas es la corteza motora, incluso la persona puede defecarse u orinarse inconscientemente. La duración de estas crisis va desde unos pocos segundos hasta minutos y su recuperación total de este estado puede incluso durar hasta horas.

**Figura 8. Epilepsia Gran Mal**



**Fuente:** GUYTON, Arthur C., HALL, John E. Tratado de Fisiología Médica. 10 ed. México: Mc-Graw Hill, 2001. 836 p.

También existe una generalidad para clasificar las convulsiones; una de las manifestaciones de la epilepsia, y la epilepsia como tal. La tabla siguiente muestra esta clasificación, fue realizada por la liga internacional contra la epilepsia desde 1985.

---

<sup>65</sup> GUYTON, Arthur C., HALL, John E. op.cit., 839 p.

## **Convulsiones**

### **I. Convulsiones Parciales o focales**

- a. Convulsiones simples y parciales
- b. Convulsiones complejas y parciales
- c. Convulsiones complejas y parciales involucrando una convulsión secundaria generalizada

### **II. Convulsiones Generalizadas (convulsivas o no convulsivas)**

- a. Ausencia
  - 1. Típica (pequeño mal)
  - 2. Atípica
- b. Mioclónica
- c. Clónica
- d. Tónica
- e. Clónico-Tónica (gran mal)
- f. Atónica

### **III. No Clasificadas**

## **Epilepsias (Clasificación abreviada)**

### **1. Epilepsias y Síndromes relacionadas con la localización**

- 1.1 Idiopática relacionada con la edad (Ej.: comenzando epilepsia infantil con picos centrotemporales)
- 1.2 Sintomática (Ej.: Epilepsia post-traumática)

### **2. Epilepsias y Síndromes Generalizados**

- 2.1 Idiopática relacionada con la edad (Ej., Epilepsia juvenil mioclónica)
- 2.2 Idiopática y/o sintomática (Ej., Síndrome de Lennox-Gastaut)
- 2.3 Sintomática

### **3. Epilepsias y Síndromes indeterminados con respecto a 1 o 2**

- 3.1 Con convulsiones parciales y generalizadas (Ej., convulsiones neonatales)
- 3.2 Sin inequívoca características generalizadas o parciales

### **4. Síndromes especiales (Ej., convulsiones febriles)**